



UNIVERSIDADE ESTADUAL DE CAMPINAS

Faculdade de Engenharia Mecânica

Marne de Miranda Sales Filho

Implementação de um Sistema de Localização Híbrido Aplicado à Navegação Autônoma de Veículos Terrestres

Implementation of a Hybrid Localization System applied to the Autonomous Navigation of Land Vehicles

CAMPINAS

2020

Marne de Miranda Sales Filho

Implementação de um Sistema de Localização Híbrido Aplicado à Navegação Autônoma de Veículos Terrestres

Implementation of a Hybrid Localization System applied to the Autonomous Navigation of Land Vehicles

Masters dissertation presented to the School of Mechanical Engineering of the University of Campinas in partial fulfillment of the requirements for the degree of Master in Mechanical Engineering, in the Area of Solid Mechanics and Mechanical Design.

Dissertação de mestrado apresentada à Faculdade de Engenharia Mecânica da Universidade Estadual de Campinas como parte dos requisitos exigidos para obtenção do título de Mestre em Engenharia Mecânica, na Área de Mecânica dos Sólidos e Projeto Mecânico.

Orientador: Prof. Dr. Janito Vaqueiro Ferreira

ESTE EXEMPLAR CORRESPONDE À VERSÃO
DE DISSERTAÇÃO DE MESTRADO DEFEN-
DIDA PELO ALUNO MARNE DE MIRANDA SA-
LES FILHO, E ORIENTADO PELO PROF. DR. JA-
NITO VAQUEIRO FERREIRA.

.....
ASSINATURA DO ORIENTADOR

CAMPINAS

2020

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Rose Meire da Silva - CRB 8/5974

Sa32i Sales Filho, Marne de Miranda, 1992-
Implementação de um sistema de localização híbrido aplicado à navegação autônoma de veículos terrestres / Marne de Miranda Sales Filho. – Campinas, SP : [s.n.], 2020.

Orientador: Janito Vaqueiro Ferreira.
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica.

1. Filtragem de Kalman. 2. Navegação autônoma. 3. Simulação computacional. 4. Veículos autônomos. I. Ferreira, Janito Vaqueiro, 1961-. II. Universidade Estadual de Campinas. Faculdade de Engenharia Mecânica. III. Título.

Informações para Biblioteca Digital

Título em outro idioma: Implementation of a hybrid localization system applied to the autonomous navigation of land vehicles

Palavras-chave em inglês:

Kalman filter

Autonomous navigation

Computer Simulation

Autonomous vehicles

Área de concentração: Mecânica dos Sólidos e Projeto Mecânico

Titulação: Mestre em Engenharia Mecânica

Banca examinadora:

Janito Vaqueiro Ferreira [Orientador]

Eurípedes Guilherme Oliveira Nóbrega

Giovani Bernardes Vitor

Data de defesa: 19-11-2020

Programa de Pós-Graduação: Engenharia Mecânica

Identificação e informações acadêmicas do(a) aluno(a)

- ORCID do autor: orcid.org/0000-0002-7988-9732.

- Currículo Lattes do autor: <http://lattes.cnpq.br/3129709153856056>

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA

DISSERTAÇÃO DE MESTRADO

Implementação de um Sistema de Localização Híbrido Aplicado à Navegação Autônoma de Veículos Terrestres

Implementation of a Hybrid Localization System applied to the Autonomous Navigation of Land Vehicles

Autor: Marne de Miranda Sales Filho

Orientador: Janito Vaqueiro Ferreira

A Banca Examinadora composta pelos membros abaixo aprovou esta Dissertação:

Prof. Dr. Janito Vaqueiro Ferreira, Presidente
DMC - Faculdade de Engenharia Mecânica - UNICAMP

Prof. Dr. Eurípedes Guilherme Oliveira Nóbrega
DMC - Faculdade de Engenharia Mecânica - UNICAMP

Prof. Dr. Giovani Bernardes Vitor
ICT - Instituto de Ciências Tecnológicas - UNIFEI

Campinas, 19 de Novembro de 2020.

Dedicatória

Aos meus pais, Marne e Valkíria, à minha companheira Ana, às minhas avós Conceição e Manoela e aos meus avôs Severino e Valdeci (*in memoriam*).

Agradecimentos

Primeiramente a Deus pela oportunidade e força para concluir este trabalho.

Aos meus pais pelo incentivo e apoio, à minha companheira por todo carinho e companheirismo.

Ao meu orientador, Prof. Dr. Janito Vaqueiro Ferreira, pela grande oportunidade que me foi dada, por todo conhecimento e ajuda, por toda confiança que me foi depositada.

Aos membros da banca de qualificação e defesa, Pablo Siqueira Meirelles, Eurípedes Guilherme Oliveira Nóbrega e Giovani Bernardes Vítor.

Aos familiares que me apoiaram, Milena, Marvin, Leopoldo, Mônica, Maria José, Helena, Naide, Délia, Maria Inez, João Maycon, Luis Fernando, Andreia e Newton.

Aos amigos George, João Paulo, Bernardo, Alain, Paulo, Otávio e Adriano por todo o tempo de descontração e amizade.

Aos amigos de laboratório German, Diana e Denner por toda ajuda e apoio.

Aos amigos Leandro Béia e Juliana Silva pela ajuda com a correção do texto.

Aos professores Olmer Garcia pela ajuda prestada ao ROS, Professor Giovani Bernardes pelo desenvolvimento da plataforma de simulação e Professor Danilo Habermann por toda ajuda com o sensor LIDAR e o tratamento da nuvem de pontos.

À UNICAMP pela estrutura e suporte prestado.

À toda equipe da SAE UNICAMP, especialmente a Cibeles pelo suporte prestado.

À FAPEMA e ao governo do Maranhão, pelo indispensável apoio financeiro.

A todos os membros do LMA, do DMC e a todos que, de alguma forma, contribuíram diretamente ou indiretamente para esta dissertação.

"A coisa mais indispensável a um homem é reconhecer o uso que deve fazer do seu próprio conhecimento."

Platão

Resumo

SALES FILHO, Marne de Miranda. **Implementação de um Sistema de localização Híbrido aplicado à Navegação Autônoma de Veículos Terrestres**. 2020. (68p). Dissertação (Mestrado). Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, Campinas.

A pesquisa de veículos autônomos vem se intensificando nos últimos anos. O principal objetivo dessa área é a condução segura e a redução de acidentes. No entanto, o alto custo dos veículos autônomos atuais ainda é uma grande barreira para a disseminação de seu uso. Visando atingir esse objetivo, trabalhos vem sendo desenvolvidos com a finalidade de reduzir o custo e aumentar a robustez e a eficiência. Considerando esses objetivos, esta pesquisa propõe um sistema de localização híbrido em ambiente simulado, para a fusão dos dados de sensores GPS, um sensor de bússola e também a saída de uma implementação de um Método de Localização Referenciado (MLR) processando sinais de um LIDAR. O método consiste inicialmente em utilizar um sistema de percepção com câmera e um sensor de distância para detectar objetos conhecidos do ambiente e consultar as suas respectivas coordenadas numa base de dados geográficos com o objetivo de assim estimar a localização do veículo. Finalmente, a implementação do filtro de Kalman para fundir os dados do MLR e dos sensores GPS e bússola. Para avaliar o desempenho do método, foi desenvolvida uma plataforma de simulação no ambiente CARLA com os dados dos sensores acessados pelo ROS. Todo o sistema simulado é executado em tempo real e seus resultados são muito consistentes com o ambiente real.

Palavras-chave: Filtro de Kalman estendido, Localização híbrida, Percepção, Mapas digitais, Plataforma de simulação, Veículos autônomos.

Abstract

SALES FILHO, Marne de Miranda. **Implementation of a Hybrid Localization System applied to the Autonomous Navigation of Land Vehicles** . 2020. (68p) . Dissertação (Mestrado). Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, Campinas.

Autonomous vehicle research has intensified in the recent years. The main objective of this area is safe driving and accident reduction. However, the high cost of current autonomous vehicles is still a major barrier to its disseminated use. In order to achieve these goals, research has been targeting to reduce cost and increase robustness and efficiency. Considering these objectives, this work proposes a hybrid localization system in a simulated environment, for the sensor fusion of GPS, a compass sensor and also the output of an implementation of a Referenced Location Method (RLM) processing LIDAR data. The method consists initially of using a perception system with a camera and a distance sensor, to detect known objects from the environment, and query the respective coordinates from a geographic database, in order to estimate the respective vehicle position. Finally, the implementation of a Kalman filter to fuse data from the RLM and the GPS and compass sensors. To assess the method performance, a simulation platform was developed in the CARLA environment with the data of the sensors accessed by ROS. The whole simulated system is executed in real time and its results are very consistent to a real environment.

Keywords: Autonomous vehicles, Digital maps, Hybrid localization, Extended Kalman filter, Perception, Simulation platform.

Lista de Ilustrações

1.1	Posição Real do veículo e do sensor GPS.	18
1.2	Posição Real do veículo, posição do sensor GPS e posição do SLH.	19
2.1	Sensores respectivamente da esquerda para direita e cima para baixo: distância, imagem, inercial e de posição.	22
2.2	Ilustração de um veículo autônomo operando em um ambiente dinâmico.	22
2.3	ROS Master permite que Nó publique informação através de um tópico o qual outro nó se subscreve para receber informação.	25
2.4	Robô com sensores embarcados operando no Gazebo.	26
2.5	Fiat Punto rodando em ambiente simulado na plataforma Morse-Blender.	26
2.6	Veículo com sensores embarcados no mundo CARLA.	27
3.1	Representação das coordenadas veículo (A) e objeto (B).	28
3.2	Representação do modelo cinemático <i>Single-Track</i>	29
4.1	Sistema de Localização Híbrido.	34
4.2	Kalman Estendido sem MLR.	34
4.3	Método de Localização Referenciada.	35
4.4	Representação do campo de visão e detecção de um objeto pela câmera.	36
4.5	Em azul os pontos detectados pelo sensor LIDAR, em amarelo a representação da distância do sensor a um determinado ponto da placa	37
4.6	Representação da área de incerteza	38
4.7	Posição do GPS e a nova posição referenciada (MLR).	39
4.8	Estrutura Final do Sistema de Localização Híbrido.	42
4.9	CARLA SERVER inicializado.	43
4.10	Veículo com sensores embarcados no simulador CARLA.	44
4.11	Tópicos ativos publicando informações dos sensores no CARLA.	44
4.12	Arquitetura de simulação.	45
4.13	Eixos de referência dos sensores.	45
4.14	Base de dados geográficos.	47
5.1	Resultado final da arquitetura de simulação e do Sistema de localização híbrido. . .	49
5.2	<i>rqt_graph</i> permite visualizar o <i>VilmaSensors</i> subscrito nos tópicos ativos através do ROSBRIDGE que estão publicando informações do CARLA.	50
5.3	Sistema de visão na arquitetura.	51
5.4	Resultado da câmera detectando a placa de trânsito (contorno em verde).	52

5.5	Nuvem de pontos.	52
5.6	Resultado da segmentação da nuvem de pontos.	53
5.7	Representação da consulta das coordenadas na base de dados.	54
5.8	Resultado da consulta na base de dados.	54
5.9	Posição real e Posição do GPS.	55
5.10	Erro do GPS nos eixos x,y e a distância do erro.	56
5.11	Filtragem sem MLR na arquitetura final.	57
5.12	Erro do EKF nos eixos x,y e a distância do erro.	58
5.13	Posição real e posição EKF.	58
5.14	Sistema de localização híbrido na arquitetura final.	59
5.15	Erro nos eixos x,y e a distância do erro.	60
5.16	Posição real e Posição SLH.	60
5.17	Dimensões da placa.	61
5.18	Posição real, posição SLH e posição EKF.	62

Lista de Tabelas

4.1	Tabela dos eixos dos sensores em relação ao modelo local.	46
5.1	Resultados	61

Lista de Abreviaturas e Siglas

Matrizes e Vetores

E, \dot{E}, E_k	- Estados do veículo
z_k	- Medição dos sensores
u_k	- Entradas de controle
F	- Jacobiano
r_k	- Ruído do sistema
v_k	- Ruído das medições
Q	- Covariância do ruído
K_k	- Ganho de Kalman
R_k	- Desvio padrão dos sensores

Letras gregas

θ	- Ângulo de orientação
ω	- Ângulo de esterçamento

Letras Latinas

L	- Distância entre os eixos traseiro e dianteiro
-----	---

Siglas

LMA	- Laboratório de Mobilidade Autônoma
ROS	- Robot Operating System
GPS	- Global Position System
EKF	- Extended Kalman Filter
VILMA	- Veículo Inteligente do Laboratório de Mobilidade Autônoma
SLH	- Sistema de Localização híbrido
MLR	- Método de localização referenciada
UniBW	- Universität der Bundeswehr München
DARPA	- Defense Advanced Research Projects Agency
CADU	- Acrônimo de Carro Autônomo
UFMG	- Universidade Federal de Minas Gerais
DMC	- Departamento de Mecânica Computacional
FEM	- Faculdade de Engenharia Mecânica
UNICAMP	- Universidade Estadual de Campinas
LIDAR	- Ligth Detection and Ranging
MCV	- Modelo Cinemático do Veículo
ROSBIDGE	- Pacote que permite troca de informações entre o ROS e outra aplicação
CARLA	- Open-source simulator for autonomous driving research
API	- Interface de Programação de Aplicações
GIS	- Geographic Information System
txt	- Arquivo de texto
JSON	- JavaScript Object Notation
UE4	- Unreal Engine 4

SUMÁRIO

Lista de Ilustrações

Lista de Tabelas

Lista de Abreviaturas e Siglas

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Problema da localização	17
1.2	Motivação	17
1.3	Objetivos	18
1.4	Proposta e Organização da dissertação	18
2	REVISÃO BIBLIOGRÁFICA	20
2.1	Veículos autônomos	20
2.2	Estado da arte	21
2.2.1	Robótica Móvel	21
2.2.2	Métodos de localização	23
	Localização Absoluta	23
	Localização Relativa	23
	Localização por Visão	24
	Localização por Mapas	24
	Localização Híbrida	24
2.2.3	Simuladores robóticos	25
3	FUNDAMENTAÇÃO TEÓRICA	28
3.1	Sistema de coordenadas	28
3.2	Modelo cinemático do veículo	29
3.3	Filtro de Kalman Estendido	31
4	METODOLOGIA	33
4.1	Sistema de localização híbrida	33
4.1.1	Introdução	33

4.1.2	Método de localização referenciada	34
4.1.3	Implementação do Filtro de Kalman Estendido	39
4.2	Plataforma de simulação	42
4.2.1	Introdução	42
4.2.2	Referencial do modelo	45
4.2.3	Base de Dados	46
5	RESULTADOS	48
5.1	Plataforma de simulação	48
5.1.1	ROSBRIDGE	49
5.2	Sistema de visão	50
5.3	Base de dados	53
5.4	GPS	55
5.5	Aplicação do filtro de Kalman estendido	56
5.5.1	Filtragem sem MLR (EKF)	56
5.5.2	Sistema de localização híbrido (SLH)	59
6	CONCLUSÃO E TRABALHOS FUTUROS	63
6.1	Conclusão	63
6.2	Trabalhos futuros	63
	REFERÊNCIAS	65

1 INTRODUÇÃO

O principal fundamento associado à construção de veículos autônomos é a possibilidade de substituir a condução humana de veículos, em tempo integral ou parcial, por uma condução automatizada e segura realizada por um sistema computacional que combine algoritmos e ferramentas de alto desempenho para sensoriamento e tomada de decisão adequada para um determinado contexto de navegação (DE SOUSA PISSARDINI *et al.*, 2013). Os veículos autônomos têm como objetivo a redução de acidentes no trânsito, que são causados, na maior parte dos casos, por fatores de imperícia, imprudência ou negligência por parte do condutor humano (BENENSON, 2008). Acidentes de trânsito (incluindo os diversos tipos de veículos e vítimas envolvidos) estão entre as dez maiores causas de morte no mundo. Ocorrem cerca de 1,35 milhões de mortes decorrentes de acidentes de trânsito no mundo, sendo que metade envolvem “usuários vulneráveis”, isto é, pedestres, motociclistas e ciclistas (ORGANIZATION *et al.*, 2018). Este capítulo apresenta toda a problemática acerca do tema e a motivação pela qual pesquisas e projetos na área continuam a ser desenvolvidas.

1.1 Problema da localização

A localização é fundamental, sem ela seria impossível a movimentação do veículo de forma autônoma, pois ele precisa de referências locais e/ou globais para que possa se locomover dentro de um determinado perímetro urbano ou outro ambiente qualquer em que esteja inserido. Para melhorar e aumentar a confiabilidade, conjunto de sensores embarcados são ferramentas indispensáveis, mas geralmente sensores com alta precisão apresentam custos muito altos. Por exemplo, existem sensores GPS com precisão de centímetros e outros com precisão em metros (TAYLOR E BLEWITT, 1999), conforme ilustra a Figura 1.1. Ainda que essas ferramentas sejam inacessíveis à grande parte da população pelo seu alto custo, a comunidade científica voltada ao desenvolvimento de novas tecnologias e redução de custos tem como propósito baratear a instrumentação, e como consequência, ter os veículos totalmente autônomos à disposição dos seres humanos.

1.2 Motivação

Visando a acessibilidade, a redução dos custos, torna-se uma necessidade, não apenas pela redução monetária dos instrumentos e sensores, mas também nos avanços de novos algoritmos e métodos mais eficazes. Os estudos de fusão dos sensores têm ganhado cada vez mais atenção no



Figura 1.1: Posição Real do veículo e do sensor GPS.

meio científico, já são muitas as pesquisas que unem dados de sensores de GPS, visão computacional e mapas digitais que podem dar estimativas de localização mais próximas ao real. A realidade atual é que sistemas mais precisos têm custos mais elevados, enquanto os de menor precisão acabam sendo mais acessíveis. A parte de localização de um robô móvel é indispensável, visto que a falta dela impossibilita a navegação, tornando-o incapaz de se deslocar com autonomia.

1.3 Objetivos

Os objetivos desta dissertação são:

- Desenvolver e implementar o sistema de localização híbrida na estrutura de desenvolvimento de software para robôs ROS.
- Desenvolver a plataforma de simulação compatível com a arquitetura do veículo autônomo VILMA para validação do método de localização proposto.

1.4 Proposta e Organização da dissertação

O sistema de localização híbrido proposto, utiliza o método de localização referenciada (MLR) que consiste no uso dos sensores de câmera e laser para detecção de objetos chaves e obter

nova informação de distância. O método utiliza sistema de mapas offline (base de dados geográficos). É possível estimar a latitude e longitude de um determinado objeto e assim obter uma nova posição de acordo com a do objeto. Além do método referenciado, são utilizados um sensor GPS de baixo custo, uma bússola e o modelo matemático do veículo. É feita a fusão de todos esses dados através do filtro de Kalman estendido (EKF), finalizando o Sistema de localização híbrido (SLH). A proposta dessa dissertação visa reduzir o erro do GPS de baixo custo e aumentar a confiança nas medidas dos sensores, conforme Figura 1.2.



Figura 1.2: Posição Real do veículo, posição do sensor GPS e posição do SLH.

Este trabalho está organizado em seis capítulos:

- O capítulo 1 trata da introdução do assunto, o problema que os veículos autônomos tentam solucionar, e os objetivos desta dissertação.
- O capítulo 2 refere-se aos trabalhos da área voltados à problemática desta dissertação: localização e fusão sensorial.
- O capítulo 3 faz um breve revisão de bibliografia relacionada aos assuntos e formulação matemática abordados na dissertação.
- O capítulo 4 apresenta a metodologia e o desenvolvimento do sistema híbrido proposto e a sua validação na plataforma de simulação.
- O capítulo 5 mostra os resultados obtidos e os gráficos referentes ao método proposto.
- O capítulo 6 conclui a dissertação e propõe futuras pesquisas e trabalhos para dar continuidade a essa linha de estudos referente aos veículos autônomos.

2 REVISÃO BIBLIOGRÁFICA

Este capítulo tem como objetivo apresentar trabalhos desenvolvidos até a presente data, que servem como base ou motivação para continuidade nos trabalhos do tema proposto nessa dissertação.

2.1 Veículos autônomos

Como pioneiro na área de carros autônomos, em meados de 1977, o Tsukuba Mechanical Engineering Lab (Laboratório de Engenharia Mecânica Tsukuba) teve seus primeiros experimentos com veículo sem motorista. O veículo chegou a atingir velocidades próximas aos 32 km/h e seguia marcadores brancos de ruas com ajuda de visão de máquina (CÁRDENAS RUEDA *et al.*, 2013).

O Dickmanns' Laboratory (Laboratório de Dickmanns), na década de 80, deu contribuição valiosa com o VaMoRs (em português: veículo de teste para mobilidade autônoma e visão computacional) do grupo de pesquisa da Universität der Bundeswehr München (UniBW), em Munique. Seu método de visão computacional conhecido como *saccadic vision* e sua velocidade chegava a 96 km/h. Mais tarde, em 1993, o VaMP Mercedes sedan trafegou milhares de quilômetros a velocidades próximas a 180 km/h pelo Eureka Prometheus Project (DICKMANNNS, 2004).

A agência DARPA (Defense Advanced Research Projects Agency) incentivou avanços na área promovendo competições, como em 2004 no grand challenge, que consistia no trajeto de 240 km com obstáculos, porém nenhuma equipe conseguiu concluir a prova, e no ano seguinte, a equipe vencedora foi a Stanford Artificial Intelligence Laboratory professor Sebastian Thrun, com o veículo Stanley VW Touareg. A agência DARPA tinha intuíto de que em um futuro próximo, pelo menos um terço dos veículos militares seriam autônomos até 2015 (THRUN *et al.*, 2006).

No Brasil, o CADU (acrônimo para Carro Autônomo) foi desenvolvido pelo Grupo de pesquisas e Desenvolvimento de Veículos autônomos da escola de engenharia da Faculdade Federal de Minas Gerais (UFMG), e a equipe liderada pelo professor Guilherme Pereira, iniciou os testes em 2017. Foram combinados GPS, acelerômetros e girômetros. Além disso, o veículo conta com dispositivos externos, como câmeras de vídeo, sensor de distância a laser e sensores ultrassônicos, os mesmos utilizados nos já conhecidos sensores de ré, instalados de fábrica em alguns modelos convencionais.

Em meados de 2008, o Laboratório de Mobilidade Autônoma (LMA) foi formado no Departamento de Mecânica Computacional (DMC) da Faculdade de Engenharia Mecânica (FEM) da Universidade Estadual de Campinas (UNICAMP), com o interesse principal em robótica móvel e segurança veicular. A plataforma robótica VILMA (Veículo Inteligente do Laboratório de Mobilidade Autônoma) está em processo de atualização do sistema de percepção, instalando uma câmera estéreo que permitirá a implementação de pesquisas já desenvolvidas e ainda não validadas na plataforma. As linhas de pesquisa principais no grupo são: Percepção, Localização, Navegação e Controle (RODRIGUEZ RUIZ *et al.*, 2014).

Em 2011, inicia-se o projeto do veículo autônomo inteligente CARINA II (Carro Robótico Inteligente para Navegação Autônomo), sendo em 2013 testado com sucesso nas ruas de São Carlos, sem intervenção de humano durante o percurso, se tornando o primeiro carro autônomo autorizado a trafegar em ruas de uma cidade (DE OLIVEIRA, 2013).

2.2 Estado da arte

Seção para revisão de trabalhos referentes ao problema de localização e fusão sensorial.

2.2.1 Robótica Móvel

Conforme cita Navarro García (2009), a robótica móvel é dividida entre a percepção, planejamento e ação. Desta forma, a utilização de sensores para os robôs móveis são indispensáveis para a fase de percepção, pois veículos autônomos necessitam de informações embarcadas para a fase de planejamento. A Figura 2.1 mostra os sensores mais utilizados.



Figura 2.1: Sensores respectivamente da esquerda para direita e cima para baixo: distância, imagem, inercial e de posição.

Os robôs conseguem perceber o ambiente em que estão através dos seus sensores (BONGARD, 2008). Existe uma grande diferença de um ambiente controlado (fábricas e laboratórios) para um ambiente dinâmico e imprevisível, tornando um grande desafio para robôs autônomos mapear e se localizar nesse ambiente (BONTEMPO, 2012). Como sensores mais precisos têm custo elevado, a utilização de sensores de baixo custo agregados a técnicas inovadoras e algoritmos podem aumentar a confiança nos dados desses sensores (SOBREIRA, 2017). A Figura 2.2 ilustra como um veículo percebe o mundo a sua volta a partir de seu sistema de percepção.




Figura 2.2: Ilustração de um veículo autônomo operando em um ambiente dinâmico.

2.2.2 Métodos de localização

Para sistemas de navegação de um veículo em uma rede rodoviária é indispensável que a sua localização tenha um elevado grau de precisão (TAYLOR E BLEWITT, 1999). A localização do robô móvel envolve a determinação da postura do robô em relação a um determinado mapa do ambiente, muitas vezes chamado de estimativa de posição ou rastreamento de posição. A localização do robô móvel é uma instância da localização geral, que é o problema perceptivo mais básico em robótica, visto que quase todas as tarefas de robótica exigem conhecimento da localização dos robôs e dos objetos que estão sendo utilizados (BONGARD, 2008). Os métodos de localização são abordados a seguir.

Localização Absoluta

Métodos de localização absoluta, comumente chamados de localização global, referem-se ao uso das informações do ambiente utilizando sensores exteroceptivos que indicam a posição em referência global do veículo (RODRIGUEZ RUIZ *et al.*, 2014). O sistema de posicionamento global (GPS) é um sistema de navegação baseado em satélites, que consiste na emissão e recepção de sinais de radiofrequência que permitem calcular posição e velocidade do veículo pela triangulação de, pelo menos, três satélites, gerando uma latitude, longitude e altitude (CÁRDENAS RUEDA *et al.*, 2013). O GPS é um dos sensores mais utilizados como ferramenta de navegação e posição no mundo, e fornece aos usuários em tempo real a posição com precisão de até 100 metros (TAYLOR E BLEWITT, 1999). Muitos trabalhos utilizam informação de GPS, dentre eles, Rodriguez Ruiz *et al.* (2014), Taylor e Blewitt (1999), TAO (2016), Ferreira e Bedoya (2018) e outros.

Localização Relativa

Métodos de localização relativa ou localização local, conforme cita Laneurit *et al.* (2003), são a posição e orientação determinadas baseadas no estado anterior. São utilizados sensores propioceptivos como odômetros e sensores inerciais. O objetivo da odometria é obter a posição e orientação a partir de encoders e sensores inerciais, para assim medir o deslocamento com uma grande precisão (CÁRDENAS RUEDA *et al.*, 2013). Alguns trabalhos desenvolvidos nessa linha são do Hide e Moore (2005), Ferreira e Bedoya (2018), Cárdenas Rueda *et al.* (2013), Navarro García (2009), dentre outros.

Localização por Visão

A percepção do ambiente é obtida através dos dados adquiridos dos diferentes sensores e pode resolver três tipos de problemas, sendo a localização do veículo dentro do ambiente inserido, a identificação dos objetos os quais estão inseridos no ambiente, e por último, a identificação da área livre ou área navegável (BERNARDES VITOR, 2014). Nesta área existem muitos trabalhos desenvolvidos para a detecção de objetos (ROSEIRO E OSÓRIO, 2017), de linhas (TAO, 2016) ou demais objetos (SOBREIRA, 2017).

Localização por Mapas

A localização baseada em mapas consiste na utilização de um sistema de informação geográfica (GIS), onde a informação pode ser utilizada como comando de navegação ou para localização quando aplicada em conjunto com GPS (RODRIGUEZ RUIZ *et al.*, 2014). A ideia de utilizar mapa digital integrado ao GPS visa diminuir o erro e aumentar a precisão da localização (TAO, 2016). Alguns trabalhos referentes a esta linha visam sistemas de localização de baixo custo com mapas são de Mattern *et al.* (2010) e Alonso *et al.* (2012).

Localização Híbrida

A localização híbrida consiste em utilizar mais de um método de localização com intuito de que um dos métodos melhore o ponto fraco do outro e vice-versa. A utilização conjunta de GPS e um sensor inercial pode gerar alta precisão e confiança na posição e orientação mesmo quando não houver dados de satélite (HIDE E MOORE, 2005). O filtro de Kalman hoje é uma das ferramentas mais empregadas para fusão sensorial. Muitos trabalhos utilizam filtro de Kalman para fazer a fusão sensorial, como Ferreira e Bedoya (2018), Sobreira (2017), Rodriguez Ruiz *et al.* (2014), Cárdenas Rueda *et al.* (2013), Mattern *et al.* (2010), dentre outros.

2.2.3 Simuladores robóticos

Simuladores são ferramentas que possibilitam testes de forma eficaz com intuito de prever erros a fim de evitar situações perigosas (RODRIGUEZ RUIZ *et al.*, 2014). Desenvolver softwares para robôs é um grande desafio, visto que as escalas e escopos dos robôs têm crescido. O ROS é uma coleção de frameworks para gerenciar a complexidade e facilitar a rápida prototipagem de software para experimentos, com ênfase na pesquisa robótica integrativa em grande escala. Isso se torna útil em uma ampla variedade de situações, à medida que os sistemas robóticos se tornam cada vez mais complexos (QUIGLEY *et al.*, 2009). O ROS, por exemplo, funciona como ferramenta que pode ser integrada a vários simuladores, inclusive plataformas robóticas reais. A Figura 2.3 mostra a estrutura de comunicação do ROS, apresentando como os nós e tópicos se comunicam com o Master.




Figura 2.3: ROS Master permite que Nó publique informação através de um tópico o qual outro nó se inscreve para receber informação.

Dentre os simuladores citam-se o Gazebo, Morse e CARLA. O Gazebo é um simulador 3D de robôs para Linux, tendo suporte para linguagens de programação C, C++ e Python e suporta aplicação do ROS, podendo simular sensores, ambientes, propriedades físicas e dinâmica (AUGUSTO, 2013). Dentre trabalhos realizados no Gazebo, cita-se Rodriguez Ruiz *et al.* (2014) e Augusto (2013). A Figura 2.4 mostra um robô inserido num ambiente de simulação Gazebo.




Figura 2.4: Robô com sensores embarcados operando no Gazebo.

Conforme cita Echeverria *et al.* (2011), o Morse é um simulador versátil, flexível e reaproveitável baseado na renderização e modelagem 3D Blender Game Engine, o qual simula em tempo real e com alta qualidade detalhes como texturas, sombras, efeitos, etc. A física do simulador é baseado em Bullet Engine, tendo aplicação para ROS e aceitando linguagens de programação C, C++ e Python. Dentre os trabalhos realizados em arquitetura Morse-Blender, citam-se Ferreira *et al.* (2015) e Fernandes *et al.* (2019). Na Figura 2.5 é possível ver um veículo dentro de um ambiente Morse-Blender.




Figura 2.5: Fiat Punto rodando em ambiente simulado na plataforma Morse-Blender.

Por último cita-se o CARLA. Para Dosovitskiy *et al.* (2017), a simulação em ambiente real requer muitos recursos, e os simuladores são uma democratização nas pesquisas já que se tornam acessíveis aos que não possuem instrumentação de custo elevado. O simulador CARLA conta com engine UE4, oferece simulação em tempo real, pode trabalhar com vários veículos, com diversos sensores embarcados e permite até simular diferentes condições climáticas, como chuvosa, ensolarada, etc. Citando os trabalhos com simulador CARLA Wu *et al.* (2020) e Dworak *et al.* (2019). A Figura 2.6 ilustra o simulador CARLA.



Figura 2.6: Veículo com sensores embarcados no mundo CARLA.

Por ser o simulador adotado pelo LMA, é o escolhido para plataforma de simulação para testes e validação da proposta.

3 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo apresentam-se assuntos fundamentais relacionados ao trabalho e que são importantes para compreensão do projeto.

3.1 Sistema de coordenadas

Para melhor entendimento do método de localização referenciada, entender a transformação das coordenadas do veículo e do objeto sendo detectado, é fundamental. O esquema da Figura 3.1, mostra o veículo como o ponto A , a uma distância d e ângulo θ do ponto B representando um objeto detectado.




Figura 3.1: Representação das coordenadas veículo (A) e objeto (B).

Sendo o ponto A o referencial global e B o referencial local. As equações para calcular a coordenada do veículo pela coordenada do objeto podem ser escritas conforme Equações 3.1 e 3.2, e tendo A como referencial global pelo objeto que está no referencial local.

$$X_A = -(d \sin \theta) + X_B \quad (3.1)$$

$$Y_A = -(d \cos \theta) + Y_B \quad (3.2)$$

E da mesma forma, as equações para calcular a coordenada do objeto pela coordenada do veículo podem ser escritas conforme Equações 3.3 e 3.4.

$$X_B = (d \sin \theta) + X_A \quad (3.3)$$

$$Y_B = (d \cos \theta) + Y_A \quad (3.4)$$

3.2 Modelo cinemático do veículo

Esta seção apresenta as equações do modelo de *Ackerman*, que é um sistema que consiste em utilizar ângulos de esterçamento das rodas dianteiras diferentes, a fim de evitar deslizamentos. O modelo simplificado de *Ackerman*, consiste no modelo *Single-Track* conforme Campbell (2007) e Siegwart *et al.* (2011).

A ideia consiste em representar as duas rodas dianteiras e traseiras em apenas uma, tendo apenas o ângulo de rotação *yaw*. O sistema de coordenadas local do veículo coincide com a roda traseira. Considera-se que θ é o ângulo formado entre o eixo x (referencial global) e o eixo x_b (referencial do veículo), e ω é o ângulo entre o eixo x_b e o eixo x_f , que consiste no ângulo de esterçamento da roda dianteira. Desta forma, o modelo do robô é considerado não-holonômico, pois possui restrições holonômicas. A Figura 3.2 representa o modelo em questão.




Figura 3.2: Representação do modelo cinemático *Single-Track*.

L é a distância entre os eixos de rodas traseiras e dianteiras, ω o ângulo de esterçamento e θ

a orientação do robô em relação ao eixo de referência global. A equação de estados é definida pela Equação 3.5.

$$E = \begin{bmatrix} x \\ y \\ \theta \end{bmatrix} \quad (3.5)$$

Considerando as restrições holonômicas, pode-se escrever as Equações 3.6 e 3.7 referentes às restrições da roda traseira 3.8 e às Equações da roda dianteira 3.9.

$$\dot{x} = v \cos \theta \quad (3.6)$$

$$\dot{y} = v \sin \theta \quad (3.7)$$

$$\dot{x}_f = \dot{x}_f \cos(\theta + \omega) \quad (3.8)$$

$$\dot{y}_f = \dot{y}_f \sin(\theta + \omega) \quad (3.9)$$

O próximo passo é colocar as coordenadas locais em relação ao sistema global de acordo com as Equações 3.10 e 3.11 e derivar, conforme mostram as Equações 3.12 e 3.13.

$$x_f = x + L \cos \theta \quad (3.10)$$

$$y_f = y + L \sin \theta \quad (3.11)$$

$$\dot{x}_f = \dot{x} - L\dot{\theta} \sin \theta \quad (3.12)$$

$$\dot{y}_f = \dot{y} - L\dot{\theta} \cos \theta \quad (3.13)$$

Ao igualar as Equações 3.8 e 3.9, tem-se a equação 3.14. Ao substituir as Equações 3.12 e 3.13 na equação 3.14, ao simplificar, tem-se a Equação 3.15.

$$\dot{x}_f \sin(\theta + \omega) - \dot{y}_f \cos(\theta + \omega) = 0 \quad (3.14)$$

$$\dot{\theta} = \frac{\dot{x} \sin(\theta + \omega) - \dot{y} \cos(\theta + \omega)}{L \cos \omega} \quad (3.15)$$

Por último, substituindo as equações da 3.6 roda traseira e 3.7 e simplificando, tem-se a Equação 3.16.

$$\dot{\theta} = \frac{v}{L} \tan \omega \quad (3.16)$$

Discretizando o modelo por Euler com o tempo de amostragem Δt , tem-se a equação para calcular a variação da posição do robô conforme Equação 3.17.

$$\begin{bmatrix} x_{k+1} \\ y_{k+1} \\ \theta_{k+1} \end{bmatrix} = \begin{bmatrix} x_k + v_k \Delta t \cos \theta \\ y_k + v_k \Delta t \sin \theta \\ \theta_k + \frac{v_k}{L} \Delta t \tan \omega \end{bmatrix} \quad (3.17)$$

3.3 Filtro de Kalman Estendido

O filtro de Kalman é uma aproximação de um estimador Bayesiano recursivo. O Filtro de Kalman estendido é um método aplicado para sistemas dinâmicos não lineares, que lineariza o sistema em torno da média e da covariância atual, empregando séries de Taylor (LJUNG, 1979), (JETTO *et al.*, 1999). O filtro baseia-se em medições de um estado anterior e tem como objetivo estimar o estado atual mais provável do veículo (NAVARRO GARCÍA, 2009).

A primeira etapa do filtro consiste na fase de estimar a próxima posição E_k e a covariância P_k . Para estimar o próximo estado, utiliza-se a predição dos estados pelo modelo dinâmico do veículo, posição anterior E_{k-1} e a parte referente à modelagem do controlador u_k do sistema. Já na estimação da covariância do modelo, utiliza-se a covariância anterior P_{k-1} , o jacobiano F_k que lineariza o sistema mais a matriz de covariância do modelo Q_k . Q_k refere-se ao ruído do modelo, erros resultantes da linearização e do nível de confiança no estado inicial do veículo. A modelagem dos valores de Q_k são extremamente importantes para o sucesso da filtragem.

$$E_k = f(E_{k-1}, u_k) \quad (3.18)$$

$$P_k = F_k P_{k-1} F_k^T + Q_k \quad (3.19)$$

A segunda etapa consiste na atualização ou correção, na qual primeiramente calcula-se o ganho de Kalman K_k , que funciona como um fator de ponderação. O ganho de Kalman definirá nas etapas seguintes, quais informações utilizar na filtragem dos dados. Dessa forma, as matrizes de covariância Q_k e R_k , que é a matriz de covariância das medições, são fatores determinantes para a filtragem, pois de acordo com seus valores, fará com que o filtro utilize ou não determinado dado do sensor ou se confiará na predição do modelo. Os valores de variância dos sensores geralmente são fornecidos pelos fabricantes, o que facilita a implementação correta da matriz referente ao ruído dos sensores. Com o valor de K_k , atualiza-se o estado E_k e depois a covariância P_{k+1} para o instante

seguinte $(k + 1)$ (RODRIGUEZ RUIZ *et al.*, 2014). m_k refere-se às medições ou dados dos sensores, H_k é a matriz de observação, a qual pode converter a grandeza física de um dado, alterar para o referencial dos sensores ou para o referencial dos estados da predição.

$$K_k = P_k H_k^T (H_k P_k H_k^T + R_k)^{-1} \quad (3.20)$$

$$E_k = E_{k-1} + K_k (m_k - H(E_{k-1})) \quad (3.21)$$

$$P_{k+1} = (I - K_k H_k) P_k \quad (3.22)$$

4 METODOLOGIA

Este capítulo apresenta a forma na qual a metodologia foi desenvolvida, apresentando inicialmente o método de localização proposto, e posteriormente, todo o desenvolvimento da plataforma de simulação construída em arquitetura similar ao VILMA, para futura validação real do sistema de localização híbrido.

4.1 Sistema de localização híbrida

Esta seção apresenta o sistema de localização híbrido, o qual é a base dessa dissertação.

4.1.1 Introdução

Como já citado nos capítulos anteriores, existe uma busca pela redução dos custos e novos métodos e tecnologias que aumentem a precisão do sistema de localização. O método de localização utilizando como referência objetos de interesse, juntamente com um sistema de visão, visa reduzir a incerteza e aumentar a precisão das medidas. Um objeto ao ser detectado pelo sistema de percepção é calculado por sua posição em relação à posição do veículo, através dos sensores disponíveis. Depois é estimada a sua posição no referencial inercial. Em seguida, a partir de uma área de incerteza escolhida em torno da posição estimada do objeto, é feita uma consulta na base de dados geográficos identificando o objeto e suas coordenadas reais. Ao se identificar o objeto na base de dados, calcula-se a posição do veículo em relação a esse objeto detectado e gera-se uma nova posição referenciada. Essa nova localização do veículo, juntamente com o sensor GPS, bússola e seu modelo matemático são fundidos com o filtro de Kalman estendido, já apresentado anteriormente no capítulo 3 conforme, Rodriguez Ruiz *et al.* (2014), ilustrado na Figura 4.1.

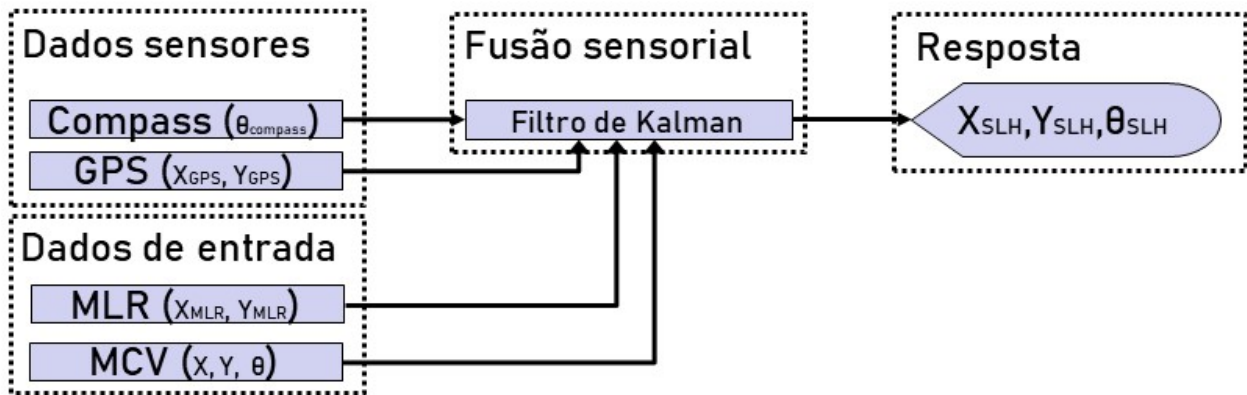


Figura 4.1: Sistema de Localização Híbrido.

Pode acontecer em alguns momentos, de não existir nenhum objeto para se referenciar, dessa forma não é possível ter a informação do MLR, e assim o filtro de Kalman estendido receberá os dados dos sensores e fundirá as informações, conforme Figura 4.2.

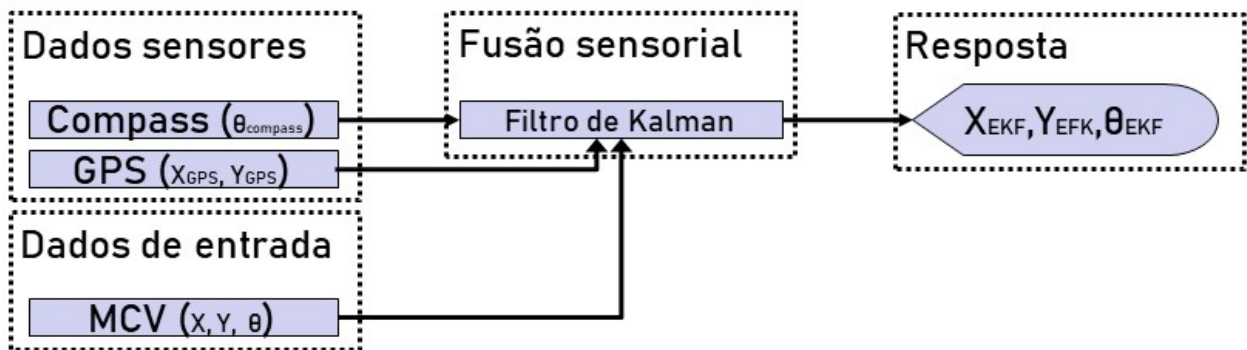


Figura 4.2: Kalman Estendido sem MLR.

Para desenvolvimento do sistema de localização híbrido, é necessário escolher o sistema de visão. A proposta é simular com os mesmos sensores embarcados do VILMA. São eles: uma câmera monocular para detecção de objetos; e um sensor LIDAR para obter a profundidade do objeto detectado.

4.1.2 Método de localização referenciada

Considerando que o veículo esteja inserido num mundo onde, por exemplo, existam placas que são um dos possíveis objetos de interesse, e se conheça a localização absoluta destas placas

através de uma base de dados geográficos, é possível obter uma nova informação de posição referente às coordenadas desse objeto. O esquema é representado na figura 4.3.

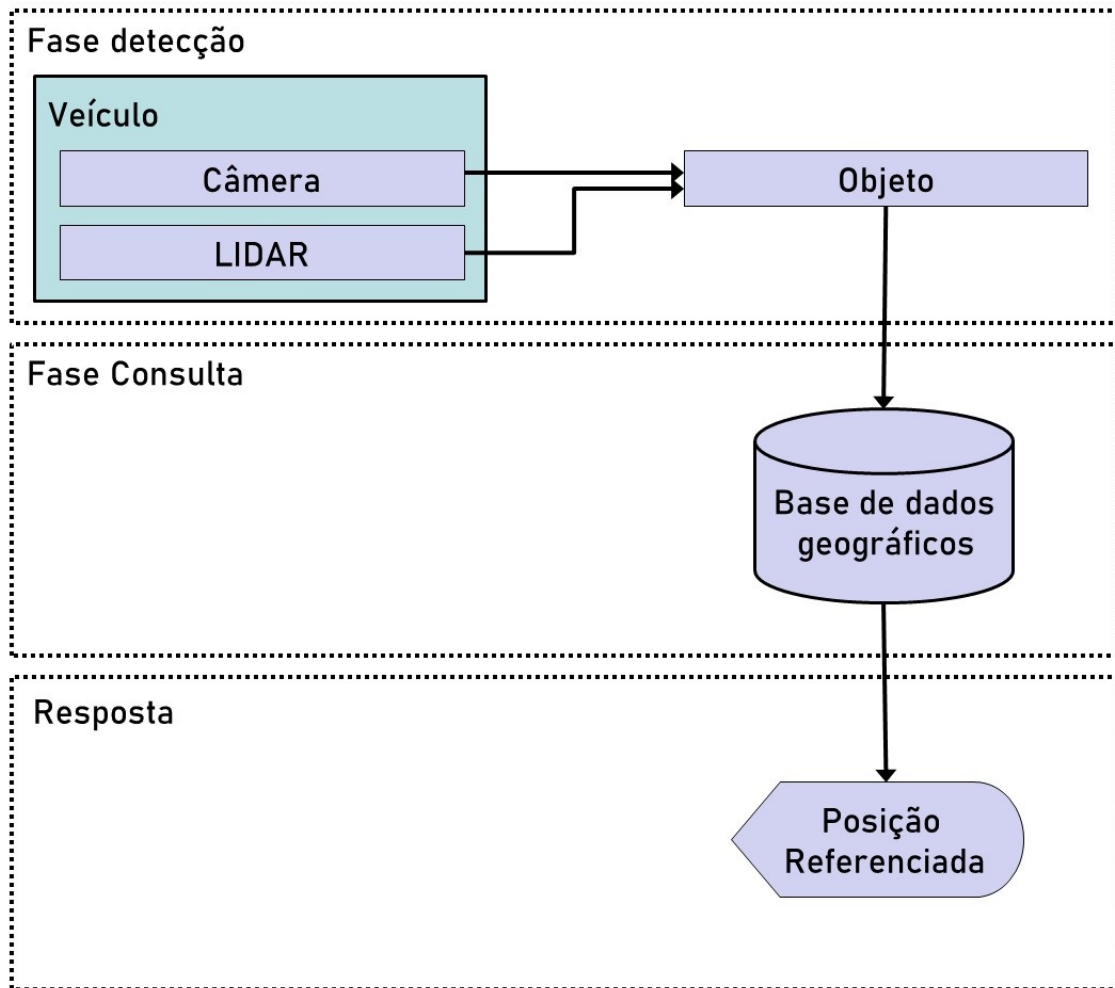


Figura 4.3: Método de Localização Referenciada.

O veículo com seus sensores embarcados é inserido em um ambiente real ou simulado. O veículo precisa perceber características do ambiente, de forma a diferenciar o que seria uma área de navegação segura, pedestres, veículos e demais itens do ambiente. Desta forma, um sensor câmera possibilita ao robô perceber esse ambiente.

Mesmo que o veículo tenha uma imagem desse ambiente, ainda é necessário interpretar essa imagem e obter informações. Para isso, aplicar uma segmentação ou filtragem da imagem com intuito de obter dados.

Muitas informações podem ser extraídas de uma imagem, a segmentação a subdivide em

regiões e sua precisão determinará o desempenho dessa análise (GONZALEZ E WOODS, 2010). Gonzalez e Woods (2010) também diz que objetos ou padrões em uma imagem são o reconhecimento de regiões individuais. No caso, esse projeto visa reconhecimento de placas de trânsito. Então realiza-se a segmentação e reconhecimento da imagem em busca de contornos característicos de placas de trânsito como formas circulares. A Figura 4.4 mostra como a câmera opera no ambiente.




Figura 4.4: Representação do campo de visão e detecção de um objeto pela câmera.

Após a segmentação e consequente detecção de um objeto tipo placa de trânsito, é necessário obter a profundidade deste objeto placa em relação ao veículo. O sensor laser LIDAR envia, feixes de lasers dentro de um raio e ângulo de alcance do sensor. Ao encontrar um obstáculo qualquer dentro desta área de acesso, o feixe de laser reflete, e com isso, é possível obter uma distância e um ângulo para cada feixe de laser refletido, gerando N números de pontos com a respectiva informação de distância, também chamada de nuvem de pontos.

A Figura 4.5 ilustra um feixe de laser detectando um obstáculo com ângulo (θ) e distância (r), juntamente a área de atuação do sensor e sua nuvem de pontos.




Figura 4.5: Em azul os pontos detectados pelo sensor LIDAR, em amarelo a representação da distância do sensor a um determinado ponto da placa

A área de oclusão é gerada pelo posicionamento do sensor LIDAR. Quanto mais próximo estiver, maior será essa área de oclusão, ressaltando que essa área também dependerá dos ângulos verticais de operação dos lasers. Os pontos gerados pelos objetos, os quais se tornaram obstáculos dos lasers, formam a nuvem de pontos. Essa nuvem de pontos ao ser filtrada pode retornar vários objetos, separando por proximidade de pontos. Essa separação gera grupos de pontos, e podem ser aplicados classificadores, de acordo com a forma que esses pontos estiverem agrupados. Pontos agrupados apenas na vertical podem indicar postes ou hastes, depende da altura máxima. Já a placa, vai possuir uma haste, e geralmente variam de 1,5 a 2 metros, o que facilita o classificador de separar dos postes, por exemplo. Além da parte circular, então um objeto que possuir pontos na horizontal (haste) e alguns pontos na sua parte superior variando em torno do eixo horizontal (placa) indicará que os pontos em questão se tratam de uma placa. Após a detecção do objeto extraído da nuvem, faz a média entre os pontos obtidos com intuito de obter o centro geométrico, e a partir deste, calcular a posição da placa detectada em relação ao veículo, conforme Equações 3.3 e 3.4.

Devido à grande possibilidade de erro referente à posição do veículo pelo GPS, é necessário estimar uma área de incerteza. Esta área abrange um determinado raio de distância da posição do objeto que deve ser proporcional ao erro da posição do veículo que no caso do GPS, é elevado.

Desta forma caso o objeto exista, ele será encontrado dentro deste raio de incerteza, conforme mostra a Figura 4.6.




Figura 4.6: Representação da área de incerteza

Após a filtragem dos pontos, obtenção da distância do objeto reconhecido, agora a próxima etapa consiste em fazer a busca desse objeto na base de dados. A consulta na base de dados resulta na informação das coordenadas reais na referência global da placa, caso ela realmente esteja dentro da base dados. Ao utilizar essa posição, é possível converter essas coordenadas pelas Equações 3.1 e 3.2 para obter a posição referenciada (MLR), que é a posição do veículo referente à posição real da placa, conforme Figura 4.7.




Figura 4.7: Posição do GPS e a nova posição referenciada (MLR).

Desta forma, completa-se o MLR, e percebe-se o quanto o método pode fornecer uma nova informação mais precisa de posição quando equiparado ao sensor GPS.

4.1.3 Implementação do Filtro de Kalman Estendido

Para finalizar o sistema de localização híbrido, realiza-se a fusão sensorial de todos os dados disponíveis com o filtro de Kalman estendido. A primeira etapa do filtro consiste na fase de predição. Propagando o estado do veículo e a covariância para cada instante do tempo k , a Equação 4.1 refere-se à predição do estado E_{k-1} (exceto no primeiro momento que se utiliza o estado inicial E_i) em relação ao seu vetor de controle u_k . Por último, calcula-se a covariância estimada P_k conforme Equação 4.2, cujo parâmetro F_k está relacionado ao Jacobiano das derivadas parciais do sistema não-linear em relação aos estados de E_k e Q_k à matriz de covariância do ruído associado a erros do estado inicial, do modelo de predição e do processo de linearização.

$$E_k = f(E_{k-1}, u_k) \quad (4.1)$$

$$P_k = F_k P_{k-1} F_k^T + Q_k \quad (4.2)$$

O modelo cinemático adotado refere-se às Equações 4.3 e a 4.4, conforme apresentada na seção 3.2, cujo parâmetro F é o Jacobiano, e x_{k+1} , y_{k+1} e θ_{k+1} são as variáveis do vetor de estados E_{k+1} que serão estimados através da equação cinemática que represente o veículo dinamicamente.

$$F = \begin{bmatrix} 1 & 0 & -v\Delta t \sin \theta \\ 0 & 1 & v\Delta t \cos \theta \\ 0 & 0 & 1 \end{bmatrix} \quad (4.3)$$

$$\begin{bmatrix} x_{k+1} \\ y_{k+1} \\ \theta_{k+1} \end{bmatrix} = \begin{bmatrix} x_k + v_k \Delta t \cos \theta \\ y_k + v_k \Delta t \sin \theta \\ \theta_k + \frac{v_k}{L} \Delta t \tan \omega \end{bmatrix} \quad (4.4)$$

A segunda etapa do filtro a ser implementada consiste na atualização ou correção das medições. Adiciona-se as medidas do GPS e do sistema de localização referenciada MLR. O cálculo do ganho de Kalman K_k é obtido pela Equação 4.5, cujos parâmetros P_k referem-se a covariância calculada na etapa anterior, H_k é a matriz de observação das funções e R_k é o desvio padrão do sensor GPS e das medidas do MLR.

$$K_k = P_k H_k^T (H_k P_k H_k^T + R_k)^{-1} \quad (4.5)$$

Utilizando o estado anterior E_{k-1} , o ganho de Kalman K_k , o vetor das medições m e a matriz de observação H , atualiza-se o estado do veículo, e para finalizar o filtro de Kalman atualiza a covariância P_{k+1} para o próximo instante de tempo do simulador.

$$E_k = E_{k-1} + K_k(m_k - H(E_{k-1})) \quad (4.6)$$

$$P_{k+1} = (I - K_k H_k) P_k \quad (4.7)$$

Os parâmetros adotados no projeto são o vetor das medições m_k obtidas e o estado inicial do veículo E_i .

$$m_k = \begin{bmatrix} X_{GPS} \\ Y_{GPS} \\ \theta \\ X_{MLR} \\ Y_{MLR} \end{bmatrix} \quad (4.8)$$

$$E_0 = \begin{bmatrix} x_0 \\ y_0 \\ \theta_0 \end{bmatrix} \quad (4.9)$$

Os valores da covariância Q_k são definidos de acordo com as necessidades e como o veículo, atuando num ambiente simulado que permite melhor controle, os valores das variâncias w_x, w_y e w_θ são relativamente baixos. No caso do parâmetro R , que representa o desvio padrão das informações, como o GPS (v_{GPS_x} e v_{GPS_y}), apresenta ruídos mais elevados, o valor adotado será bem maior quando comparado à bússola, que tem erros bem próximos de 0. A confiança nas informações do MLR (v_{MLR_x} e v_{MLR_y}) por ter uma confiança maior, adota-se valores menores que o do sensor GPS.

$$Q = \begin{bmatrix} w_x & 0 & 0 \\ 0 & w_y & 0 \\ 0 & 0 & w_\theta \end{bmatrix} \quad (4.10)$$

$$R = \begin{bmatrix} v_{GPS_x} & 0 & 0 & 0 & 0 \\ 0 & v_{GPS_y} & 0 & 0 & 0 \\ 0 & 0 & v_\theta & 0 & 0 \\ 0 & 0 & 0 & v_{MLR_x} & 0 \\ 0 & 0 & 0 & 0 & v_{MLR_y} \end{bmatrix} \quad (4.11)$$

A Figura 4.8 mostra a estrutura final do sistema de localização híbrido.

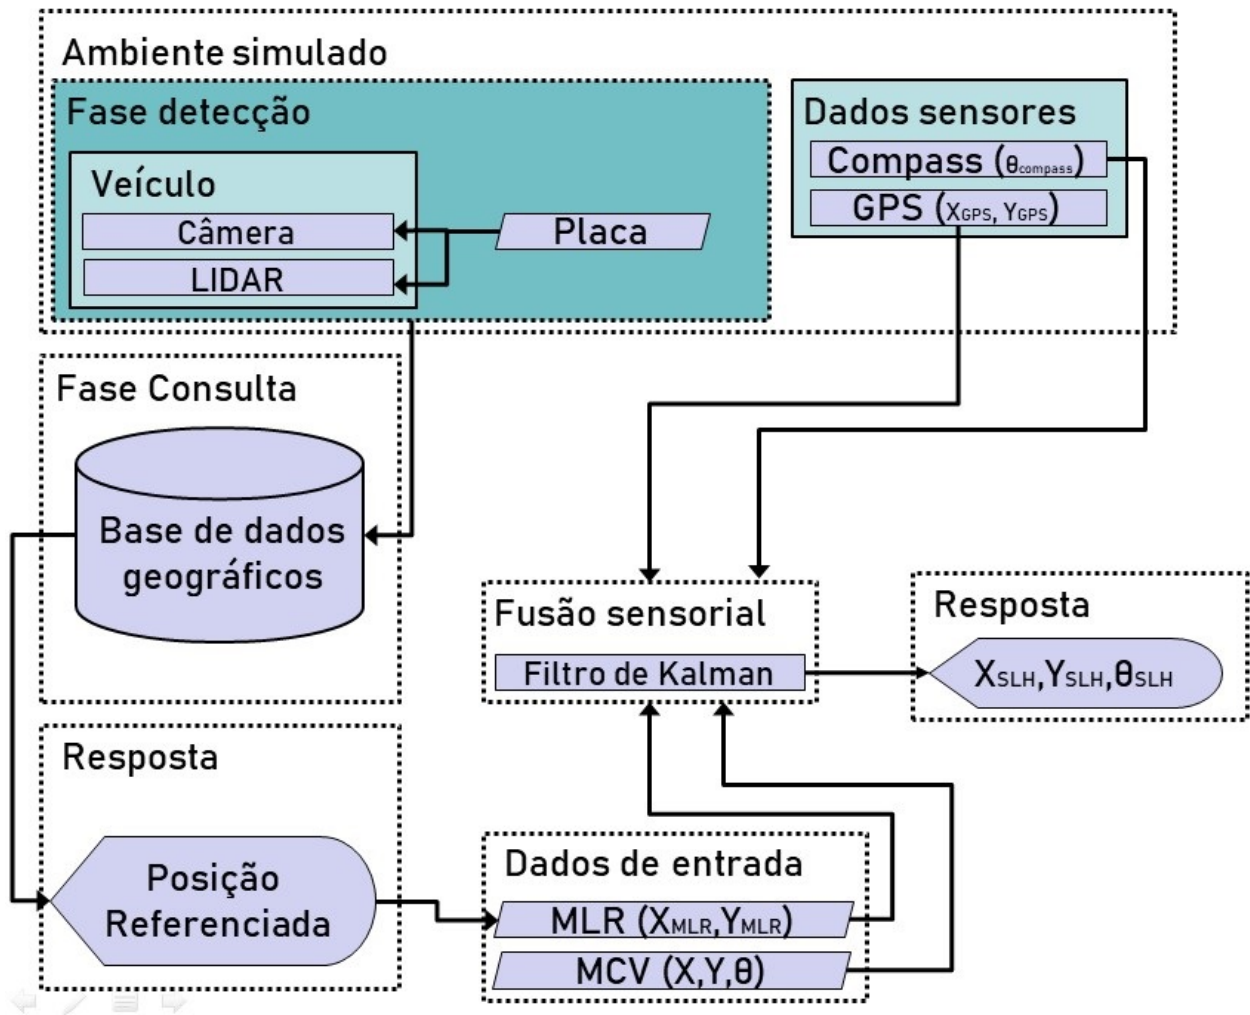


Figura 4.8: Estrutura Final do Sistema de Localização Híbrido.

4.2 Plataforma de simulação

Esta seção apresenta toda a arquitetura do simulador empregado para validar o método proposto anteriormente.

4.2.1 Introdução

Para validação do sistema de localização híbrido, torna-se necessária a utilização de uma plataforma que simule os sensores embarcados do veículo juntamente a um ambiente onde o veículo deve estar inserido. O simulador robótico CARLA é uma das plataformas que já possui o pacote

ROSBRIDGE, que permite receber os plugins do simulador através do ROS. Para rodar o simulador CARLA, inicia-se o servidor que inicializa todo ambiente de simulação, onde encontram-se as estradas, construções, sinalizações e etc. Enquanto esse servidor estiver ativo, é possível inserir novos objetos a esse mundo, sendo eles veículos, pessoas, etc. A Figura 4.9 mostra o CARLA SERVER sendo executado.




Figura 4.9: CARLA SERVER inicializado.

Os objetos podem ser inseridos no ambiente com o API (do inglês, *Application Programming Interface*), que além de veículos, sensores e novos objetos, também possui comandos de navegação para o veículo e pode definir também as posições as quais itens serão inseridos. O API insere o veículo com câmera, bússola, GPS e LIDAR. A partir daí o ambiente está pronto para simular o Sistema proposto conforme Figura 4.10.



Figura 4.10: Veículo com sensores embarcados no simulador CARLA.

Porém, torna-se necessário utilizar o ROS conforme a arquitetura do VILMA. Então, inicializa-se o pacote CARLA ROSBRIDGE, que torna possível o acesso a todos os plugins disponíveis do ambiente CARLA, conforme Figura 4.11.

```

janito@LMA: ~ 57x19
(base) janito@LMA:~$ rostopic list
/carla/hero/camera/rgb/front/camera_info
/carla/hero/camera/rgb/front/image_color
/carla/hero/enable_autopilot
/carla/hero/gnss/front/fix
/carla/hero/lidar/front/LIDAR
/carla/hero/objects
/carla/hero/odometry
/carla/hero/vehicle_control_cmd
/carla/hero/vehicle_info
/carla/hero/vehicle_status
/carla/map
/carla/objects
/carla/vehicle_marker
/clock
/rosout
/rosout_agg
/tf
(base) janito@LMA:~$

```

Figura 4.11: Tópicos ativos publicando informações dos sensores no CARLA.

Agora que os plugins estão acessíveis pelo ROS, o nó subscrive para acessar os dados dos sensores e permite que o algoritmo de localização seja implementado. Esse nó também acessará as informações referentes à base de dados geográficos. A Figura 4.12 ilustra a arquitetura citada anteriormente.

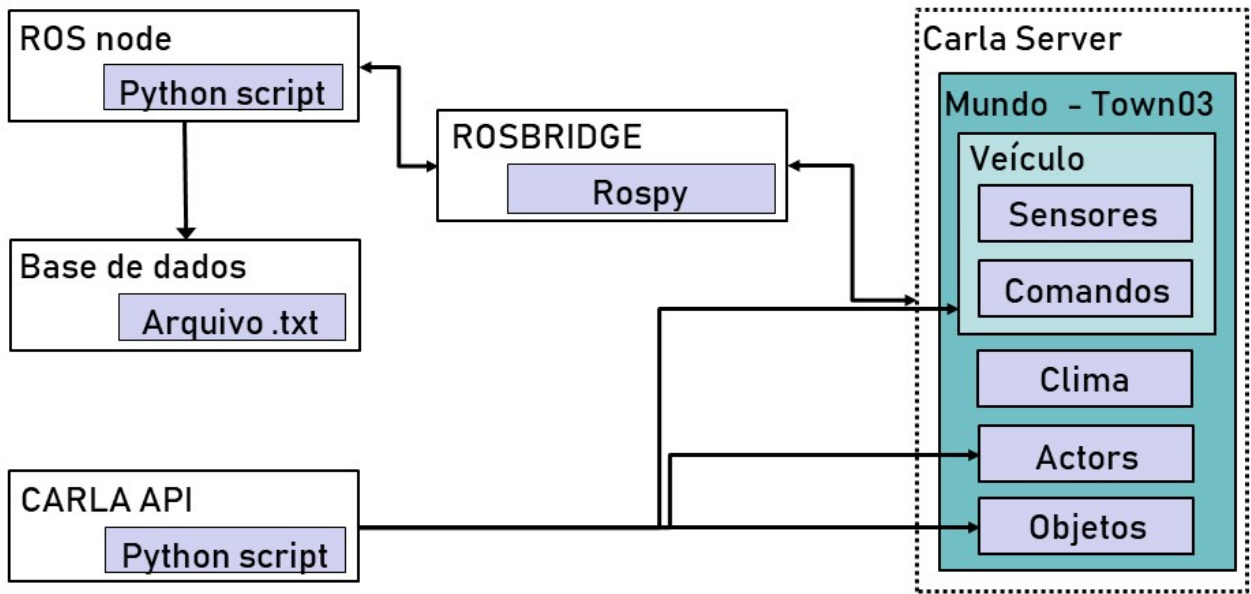


Figura 4.12: Arquitetura de simulação.

4.2.2 Referencial do modelo

Torna-se necessário definir o referencial dos sensores em relação ao referencial local do veículo. A origem adotada fica no centro geométrico do veículo (X_{car} , Y_{car}) e na base do chassi (Z_{car}), conforme ilustra a Figura 4.13.



Figura 4.13: Eixos de referência dos sensores.

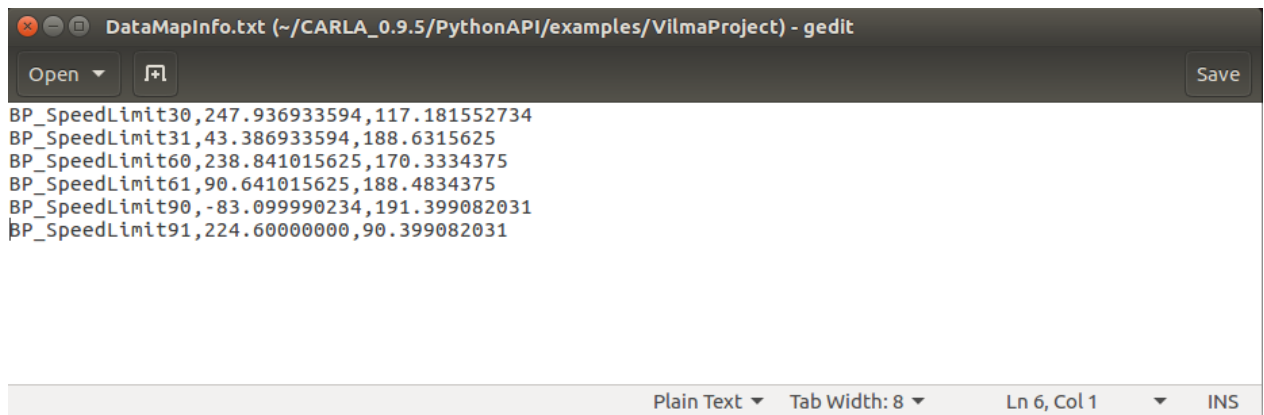
A partir das coordenadas do referencial define-se também a posição dos sensores. A Tabela 4.1 define as posições dos eixos de referência dos sensores.

Tabela 4.1: Tabela dos eixos dos sensores em relação ao modelo local.

Posição	x	y	z	Unidade
GPS	0	0	1,3	m
Câmera	0	0	1,3	m
Rotação câmera	0	0	0	rad
LIDAR	0	0	2,8	m
Referencial veículo	0	0	0	m

4.2.3 Base de Dados

As coordenadas dos objetos de interesse inseridas na base de dados, que será consultada pelo MLR, foram extraídas de forma manual do CARLA. É possível criar esta base de dados com dados geográficos no formato GIS, que são normalmente utilizados em organizações de mapeamento open-source. Entretanto, estes dados podem ser convertidos para formatos mais leve para melhorar a performance de consulta como um arquivo em formato *".txt"* ou *".JSON"*. Foi adotado o formato *".txt"* para o sistema de mapas desenvolvido pela sua simplicidade de criação e acesso. Devido à limitação apresentada pela versão 0.9.6, não é possível alterar o mapa com a utilização de uma ferramenta open-source, limitando a utilização do *Open Street Map*. Desta maneira, a forma encontrada de contornar o problema, foi extrair as informações geográficas do mapa *Town03* do CARLA de forma manual. A base de dados foi desenvolvida apenas com objetos de interesse para o método, neste caso as placas e tendo sua posição em coordenadas cartesianas, para facilitar a consulta. A base de dados simplificada é exibida na Figura 4.14.



```
BP_SpeedLimit30,247.936933594,117.181552734
BP_SpeedLimit31,43.386933594,188.6315625
BP_SpeedLimit60,238.841015625,170.3334375
BP_SpeedLimit61,90.641015625,188.4834375
BP_SpeedLimit90,-83.099990234,191.399082031
BP_SpeedLimit91,224.600000000,90.399082031
```

Plain Text ▾ Tab Width: 8 ▾ Ln 6, Col 1 ▾ INS

Figura 4.14: Base de datos geográficos.

5 RESULTADOS

Este capítulo apresenta os resultados da metodologia proposta nessa dissertação. Apresenta-se os resultados do ambiente de simulação, dos sensores, da arquitetura e do sistema de localização híbrido.

5.1 Plataforma de simulação

Os resultados da primeira fase do método de localização referenciada são a detecção do objeto pela câmera e a obtenção da distância através dos dados recebidos pelo sensor LIDAR. Depois, a segunda etapa consiste na consulta da base de dados para obter-se a nova posição referenciada. Por último, a fusão sensorial de todos os dados embarcados através do filtro de Kalman estendido, que resulta no sistema de localização híbrido. A Figura 5.1 mostra o resultado final do método e da arquitetura, sendo o verde representado pelo sistema de informações geográficas offline, azul representando o sistema do ROS, laranja todo o ambiente de simulação CARLA e em roxo os dados de entrada dos sistema. T1 refere-se à transformação de coordenadas local para global e T2 de global para local.

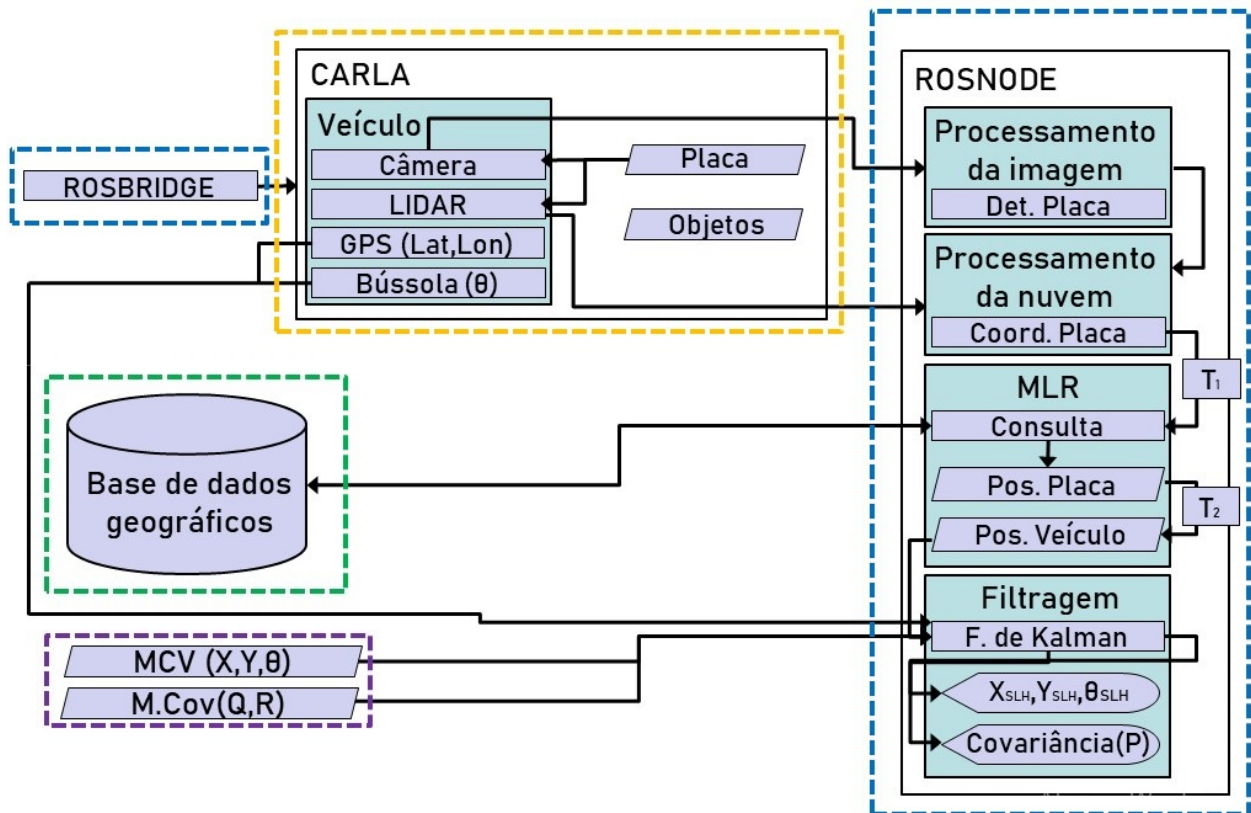


Figura 5.1: Resultado final da arquitetura de simulação e do Sistema de localização híbrido.

5.1.1 ROSBRIDGE

Com o ambiente simulado operando, através do ROS, tem-se acesso aos dados que são publicados nos sensores no mundo virtual do CARLA. A Figura 5.2 demonstra o ROSBRIDGE acessando toda a informação dos sensores no ambiente CARLA e enviando as informações para o nó de subscrição. A visualização é feita através da ferramenta do ROS, *rqt_graph*, que permite visualizar todas informações ligadas ao ROS.

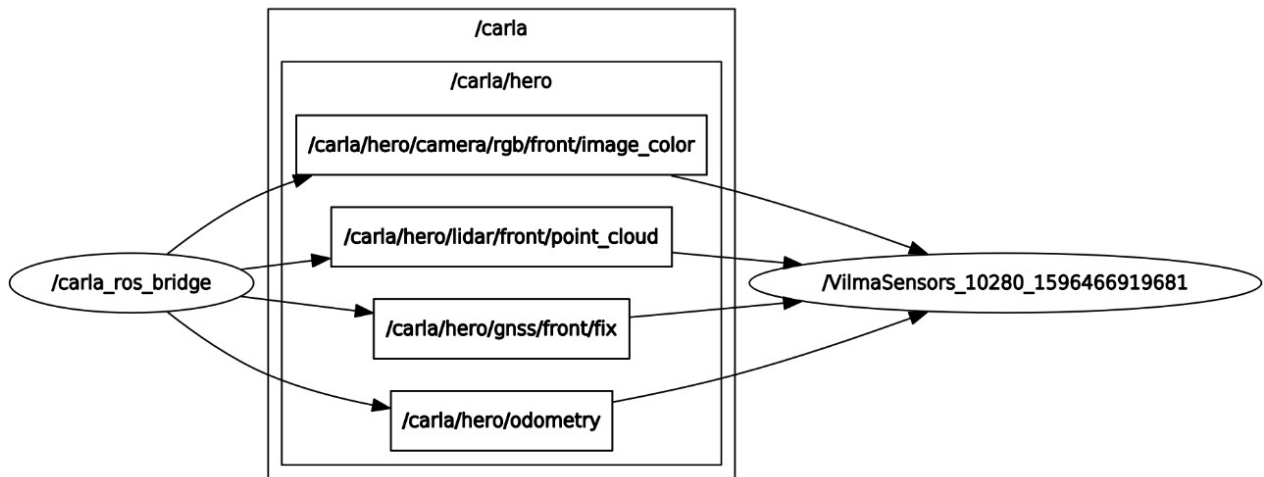


Figura 5.2: *rqt_graph* permite visualizar o *VilmaSensors* subscrito nos tópicos ativos através do ROSBRIDGE que estão publicando informações do CARLA.

5.2 Sistema de visão

O sistema de visão do veículo refere-se aos sensores que tem como objetivo perceber o ambiente a sua volta. É comum a utilização de um sistema de visão baseado em câmeras estéreo conforme Giovanni *et al.* (2015), ou baseado em câmera monocular e um sensor de distância, conforme Rodriguez Ruiz *et al.* (2014).

Devido à necessidade do projeto de desenvolver o método com os sensores disponíveis no VILMA, foram escolhidos seus sensores, o sistema de câmera monocular e um sensor de distância LIDAR, para testar o desempenho do MLR. A representação do sistema de visão é mostrado em vermelho na Figura 5.3 junto à arquitetura final.

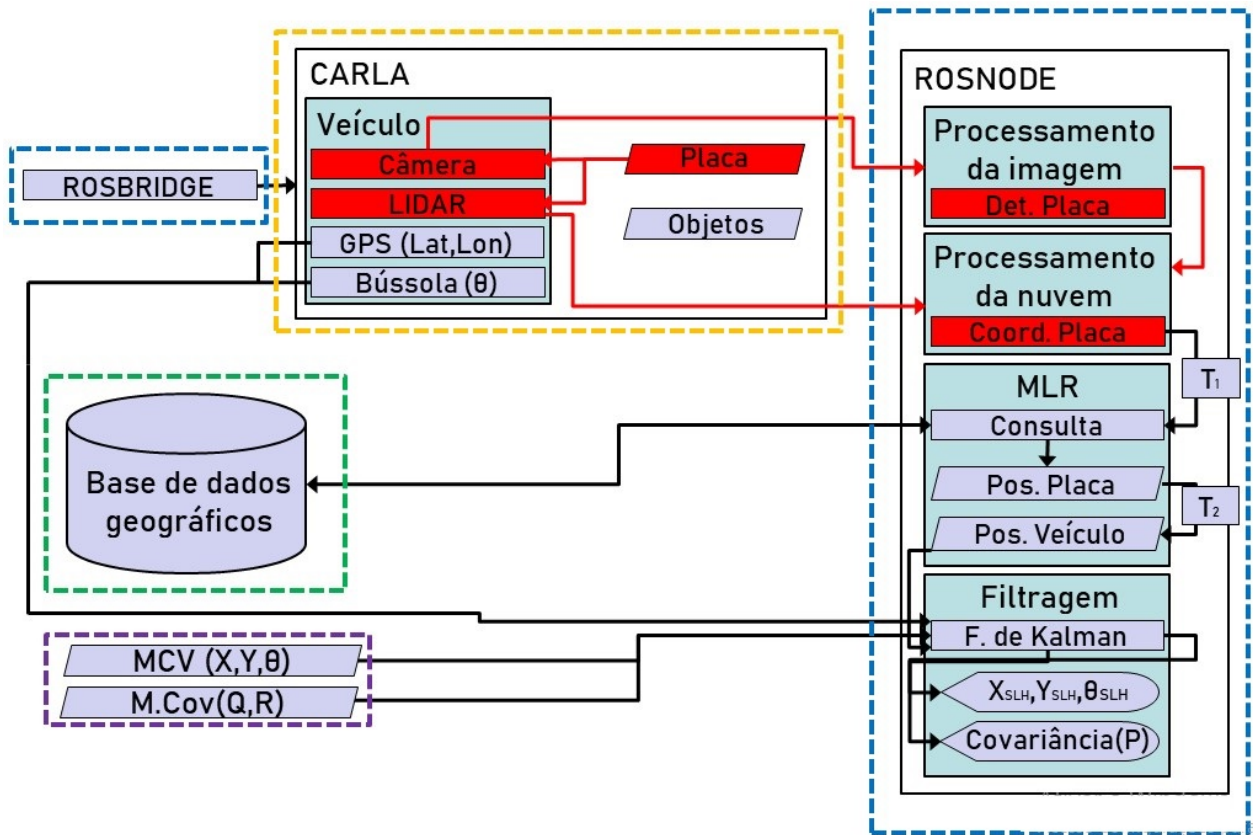


Figura 5.3: Sistema de visão na arquitetura.

A primeira etapa do sistema de visão consiste na detecção do objeto através da imagem. A segmentação da imagem é um processo bem exaustivo para testar cada tipo de filtro ou até mesmo utilizar vários até encontrar o mais adequado à aplicação requerida. Lembrando que o único objetivo do tratamento de imagens é para o caso específico de detectar contornos e formas circulares. Um problema recorrente para análise e processamento de imagens são as variações de luminosidade, que afetam diretamente os filtros. A primeira etapa é converter a imagem para tons de cinza, utilizando a função *cvtColor* da biblioteca *Opencv*. Para facilitar a detecção de contornos, aplica a função *blur* da biblioteca *Opencv* para borrar a imagem. Para segmentar a imagem aplica-se a função *Canny* da biblioteca *Opencv*. Por último, utiliza-se a função *find_contours* da biblioteca *Opencv* para detectar o contorno da placa, que é exibido na Figura 5.4.



Figura 5.4: Resultado da câmera detectando a placa de trânsito (contorno em verde).

O resultado do processamento retorna ao sistema que existe uma placa de trânsito. Desta forma, no algoritmo retorna como verdadeiro (que existe um objeto detectado) e assim entra na rotina da filtragem da nuvem de pontos para encontrar a distância dessa placa. A nuvem de pontos gerada pelo sensor de distância LIDAR, mostrada na Figura 5.5, pelo visualizador da biblioteca *pptk* com a função *viewer*.




Figura 5.5: Nuvem de pontos.

A segmentação da nuvem de pontos visa separar os objetos dentro da nuvem pela proximidade entre os pontos, desta forma, geram grupos de pontos, que consistem em objetos separados pela sua proximidade uns com outros. Após a separação dos objetos, é aplicada uma rotina que visa separar os grupos de objetos pelas características que os pontos formam. Como a placa possui uma haste (pontos próximos verticalmente) e a placa (região com pontos aglomerados na região superior a haste) é possível diferenciar de outros objetos. A visualização dessas características ficam bem visíveis na Figura 5.6, que é o resultado da segmentação e obtenção dos pontos referentes à placa de trânsito.




Figura 5.6: Resultado da segmentação da nuvem de pontos.

Após a segmentação e cálculo da média dos pontos, tem-se a distância e o ângulo em relação ao ponto médio do objeto. Calcula-se a coordenada no objeto no plano global, conforme Equações 3.3 e 3.4, utilizando as coordenadas do veículo (GPS).

5.3 Base de dados

Esta seção apresenta os resultados referentes às informações geográficas, que dizem respeito à base de dados e sua utilização. A arquitetura da base de dados e a consulta são mostrados em vermelho na Figura 5.7.

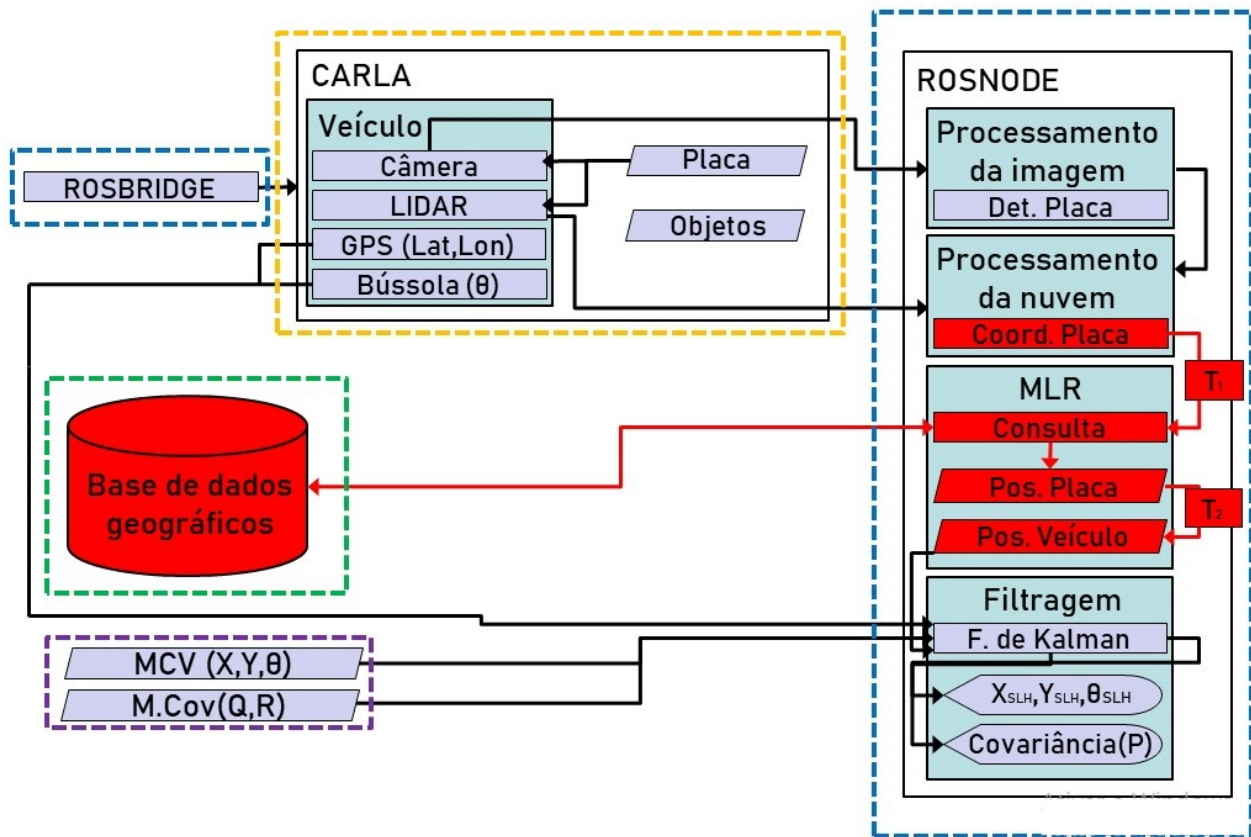


Figura 5.7: Representação da consulta das coordenadas na base de dados.

Para finalizar o método de localização referenciada, após a detecção do objeto e obtenção das coordenadas do mesmo, é feita a consulta na base de dados levando em conta a área de incerteza que é proporcional ao ruído do GPS. Caso o objeto exista na base de dados, ele retornará a coordenada real do objeto, e através da transformação das suas coordenadas para o referencial do veículo, conforme Equações 3.1 e 3.2, obtendo a posição referenciada. A figura 5.8 mostra o resultado da detecção do objeto a qual calcula-se a distância e o ângulo e a consulta desse objeto.

```

Janito@LMA: ~/CARLA_0.9.5/PythonAPI/Examples/VilmaProject 78x74
A distancia do veículo até o ponto é 34.132801819 e seu ângulo é 78.48400648
Objeto detectado consta na Base de dados: BPSpeedLiimit30
A distancia do veículo até o ponto é 34.132801819 e seu ângulo é 78.48400648
Objeto detectado consta na Base de dados: BPSpeedLiimit30
A distancia do veículo até o ponto é 34.132801819 e seu ângulo é 78.48400648
Objeto detectado consta na Base de dados: BPSpeedLiimit30
  
```

Figura 5.8: Resultado da consulta na base de dados.

5.4 GPS

O GPS do CARLA é ideal, bem diferente do real. Dessa forma foi necessário modelar um GPS com ruído gaussiano de determinado desvio padrão para que ele fique num contexto mais próximo da realidade de um GPS de baixo custo. O resultado desse GPS é mostrado comparando com a posição real (GPS ideal) na Figura 5.9.




Figura 5.9: Posição real e Posição do GPS.

Desta forma, conforme a Figura 5.10, é possível visualizar os erros de posição do GPS em x, y e a distância do erro em xy. A média do ruído chega aproximadamente aos 6 metros.




Figura 5.10: Erro do GPS nos eixos x,y e a distância do erro.

5.5 Aplicação do filtro de Kalman estendido

Em situações normais de operação haverá momentos em que nenhum objeto de referência será detectado. Nesse caso, os dados são filtrados apenas com os dados dos sensores GPS e bússola. Porém, quando existirem objetos de referência, a nova informação será inserida no filtro. Nesta seção apresentam-se os dois estados possíveis para filtragem dos dados, conforme citado na subseção 4.1.1.

5.5.1 Filtragem sem MLR (EKF)

Na Figura 5.11, em vermelho, representa o esquema da filtragem dos dados sem o MLR dentro da arquitetura final do sistema.

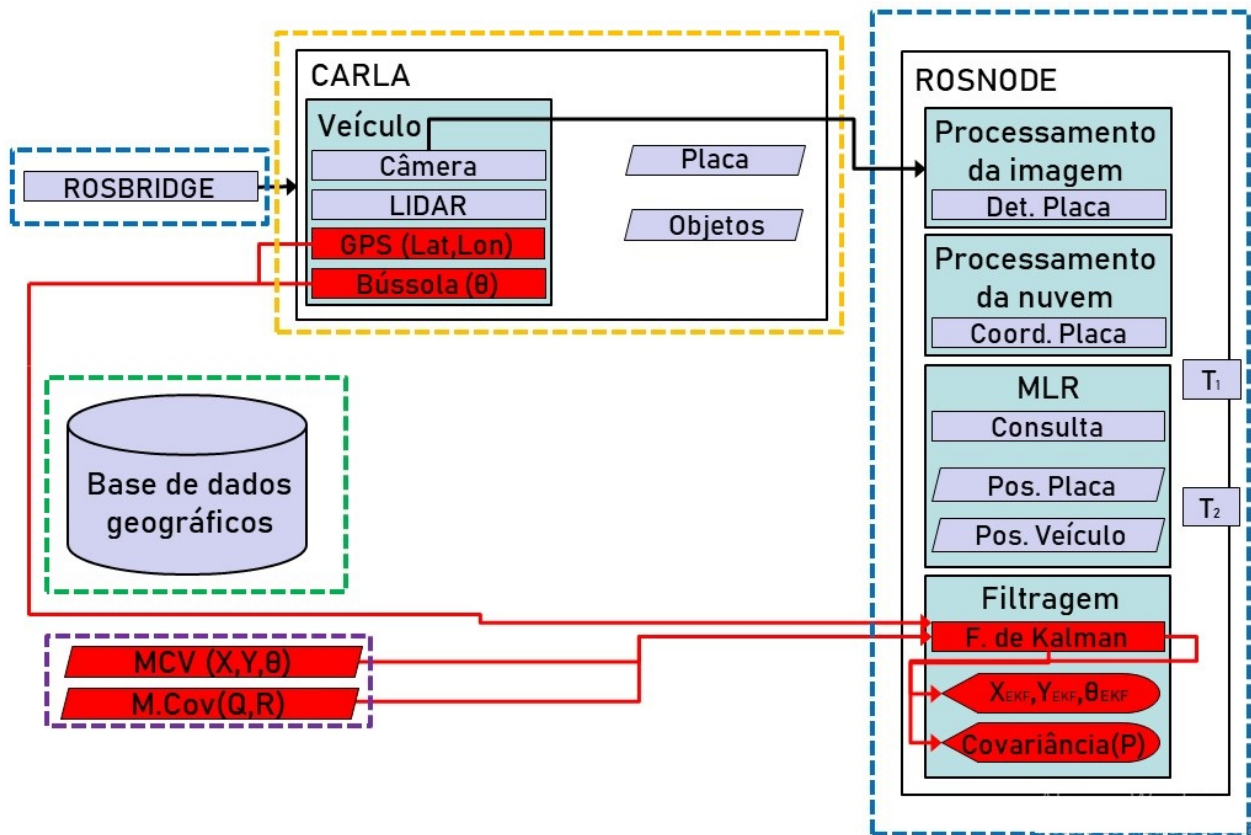


Figura 5.11: Filtragem sem MLR na arquitetura final.

A Figura 5.12 mostra os erros referentes ao eixo x, y e distância do erro. Já nota-se uma grande redução do ruído quando equiparado ao sensor GPS. O erro máximo chegou a 3,25 metros e a média do erro foi reduzida aos 1,78 metros.




Figura 5.12: Erro do EKF nos eixos x,y e a distância do erro.

Conforme Figura 5.13, é visível que quando comparado com o GPS, a filtragem dos dados melhora a posição. Dessa forma aumenta a confiabilidade da localização, que ainda não é ideal, lembrando que qualquer coisa acima de 0,5 metros é extremamente perigoso para um veículo autônomo em um ambiente real, onde existam seres humanos.




Figura 5.13: Posição real e posição EKF.

5.5.2 Sistema de localização híbrido (SLH)

Em vermelho é possível ver na Figura 5.14 o esquema desta subseção, conforme a arquitetura final do sistema.

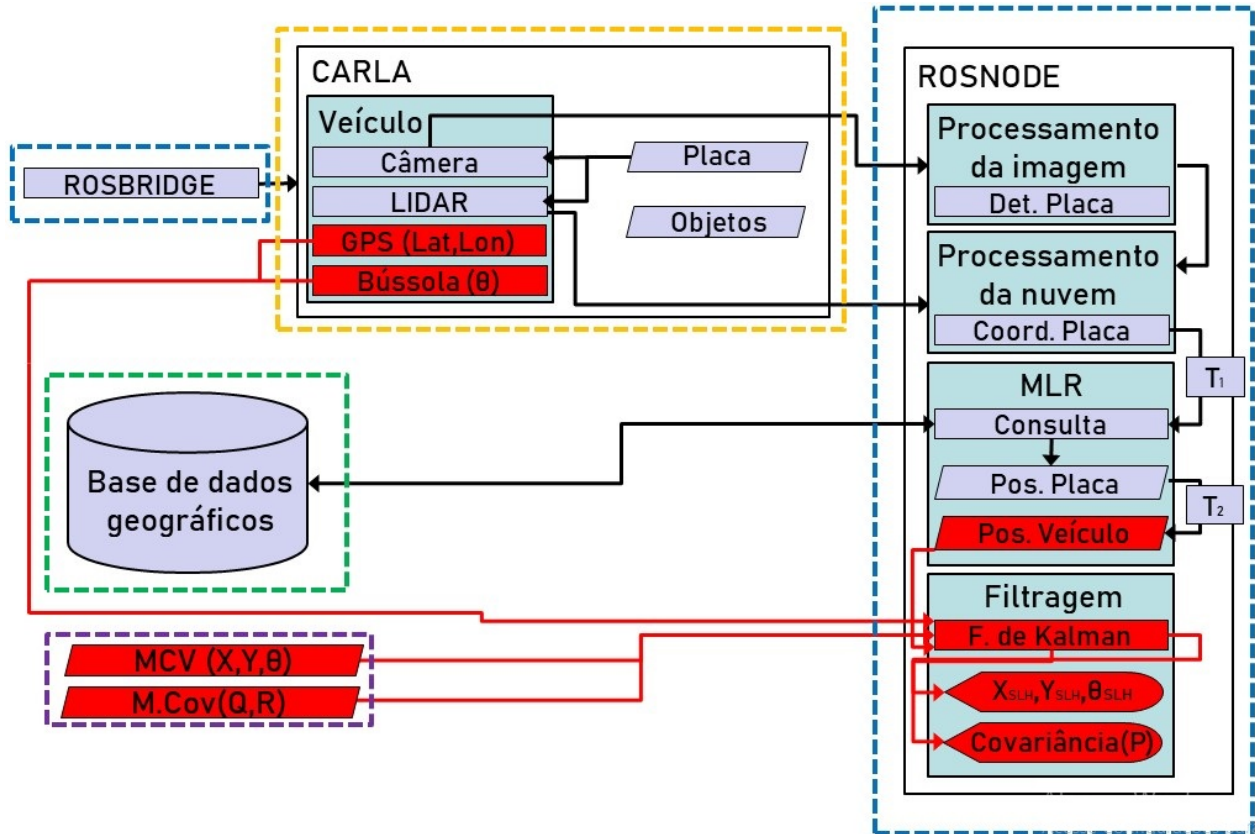


Figura 5.14: Sistema de localização híbrido na arquitetura final.

O sistema proposto nesta dissertação teve resultados muito próximos da posição real. Conforme mostra a Figura 5.15, os erros nos eixos x e y ficaram na questão de centímetros, ressaltando que o erro no eixo y ficou muito próximo do zero. A média do erro ficou em 0,12 metros, com erro máximo de 0,32 metros.




Figura 5.15: Erro nos eixos x,y e a distância do erro.

A Figura 5.16 consegue ressaltar o quanto o erro foi reduzido quando comparado aos resultados anteriores. Os valores das posições chegaram bem próximos, tornando o sistema de localização do veículo com um nível excelente de confiança.




Figura 5.16: Posição real e Posição SLH.

Figura 5.16: Posição real e Posição SLH.

Mesmo que o sistema de percepção não esteja nos objetivos do trabalho, vale ressaltar que os erros gerados por esse sistema são devido às imprecisões de processamento de detecção do posicionamento da placa, considerando que para o laser é difícil conseguir gerar pontos com exatidão da localização do referencial do centro da placa, já que não se pode garantir que os pontos estarão exatamente nas extremidades (que possibilita encontrar o centro através da média desses pontos). Dessa forma, de acordo com a dimensão dos objetos que constituem uma placa de trânsito, estes podem gerar esse ruído. Por exemplo, uma haste de uma placa pode gerar erros de até 8 centímetros. Já a espessura da placa no simulador, chegam até 7 centímetros (placas reais que são feitas de chapas, essa espessura seria bem menor) e 80 centímetros de altura e comprimento. As dimensões da mesma podem ser vistas na Figura 5.17.




Figura 5.17: Dimensões da placa.

Conforme mostrado anteriormente, os resultados das filtrações são exibidas na Figura 5.18 e a média, máximo, mínimo e o desvio padrão dos erros são mostradas na Tabela 5.1.

Tabela 5.1: Resultados

Erro	GPS	EKF	SLH	Unidade
Distância máxima	14,993	3,258	0,328	m
Distância mínima	0,273	0,678	0,009	m
Distância média	6,007	1,782	0,129	m
Desvio Padrão	3,086	0,420	0,081	m




Figura 5.18: Posição real, posição SLH e posição EKF.

6 CONCLUSÃO E TRABALHOS FUTUROS

Este capítulo apresenta as conclusões retiradas dos resultados e a sua relevância e contribuição dentro da robótica móvel. Consequentemente, apresenta as linhas de continuação do estudo apresentado nessa dissertação.

6.1 Conclusão

Os resultados mostram a eficiência que uma localização por referência pode trazer ao sistema. Aumenta consideravelmente a confiabilidade nas informações para localização. Nota-se que a filtragem dos dados embarcados teve uma redução do erro de até 15 metros do GPS, para aproximadamente 32 centímetros, o que resulta numa redução de quase 98% do erro. Para a robótica móvel, é extremamente interessante, porém esse método tem suas limitações visto que não será sempre que haverá objetos para referenciar-se.

Vale ressaltar que o sensor laser quando se trata de detecção do objeto, em relação aos pontos que encontram a placa, não se tem a certeza que estará no centro de referência da placa no banco de dados (o que dificilmente acontece). Dessa forma, para reduzir o erro é necessário fazer uma média dos pontos para obter o mais próximo do seu centro geométrico real.

A plataforma de simulação mostrou eficácia, retirando a limitação da versão CARLA de não poder agregar ferramentas como *Open Street Map*, foi capaz de simular o ambiente, o veículo e seus sensores sem apresentar nenhuma restrição ou falhas.

O projeto visa contribuir com sistemas de localização de baixo custo, visto que os erros de GPS de baixo custo geram dados de baixa exatidão. Dessa forma, tentar mesclar novas informações pode tornar o sistema cada vez mais preciso.

6.2 Trabalhos futuros

Propor novas informações de outros sensores para aplicação do filtro de Kalman estendido para aumentar a robustez, como um sistema de odometria com encoders, considerando que é comum o GPS perder o sinal dependendo da região. Pode ser aplicado o sistema utilizando visão

estéreo para testar a precisão da distância, já que foi uma limitação encontrada no sistema câmera-laser.

Melhorar o sistema de visão, de acordo com as limitações encontradas no projeto. Aumentar a eficiência do sistema para reconhecer mais objetos com uso de aprendizado de máquina ou redes neurais. Essas ferramentas seriam poderosas opções para o sistema conseguir diferenciar vários tipos de objetos que podem ser inseridos na base de dados geográficos. Resultando em maior possibilidade de referenciar-se por objetos inseridos no ambiente.

REFERÊNCIAS

ALONSO, I.; FERNÁNDEZ LLORCA, D.F.; GAVILAN, M.; ÁLVAREZ PARDO, S.; GARCIA-GARRIDO, M.; VLACIC, L. e SOTELO, M. Accurate global localization using visual odometry and digital maps on urban environments. **IEEE Transactions on Intelligent Transportation Systems**, v. 13, n. 4, 1535–1545, 2012.

AUGUSTO, Gonçalo Nuno dos Santos. **RobotTeamSim–3D visualization of cooperative mobile robot missions in gazebo virtual environment**. 2013. Tese (Doutorado).

BENENSON, Rodrigo. **Perception pour véhicule urbain sans conducteur: conception et implementation**. 2008. Tese (Doutorado). Paris, ENMP.

BERNARDES VITOR, Giovani. **Urban environment perception and navigation using robotic vision : conception and implementation applied to autonomous vehicle**. setembro 2014. , n. 2014COMP2155. Theses. Université de Technologie de Compiègne.
URL: <https://tel.archives-ouvertes.fr/tel-01127460>

BONGARD, J. Probabilistic robotics. sebastian thrun, wolfram burgard, and dieter fox.(2005, mit press.) 647 pages. 2008.

BONTEMPO, Alan Porto. **Uma Abordagem Híbrida para Localização e Mapeamento Simultâneos para Robôs Móveis com Sonares Através de Filtro de Kalman Estendido**. 2012. Tese (Doutorado). PUC-Rio.

CAMPBELL, Stefan Forrest. **Steering control of an autonomous ground vehicle with application to the DARPA urban challenge**. 2007. Tese (Doutorado). Massachusetts Institute of Technology.

CÁRDENAS RUEDA, M.Á. *et al.* Localização híbrida para um veículo autônomo em escala usando fusão de sensores: Hybrid localization for an scale r/c car using sensor fusion. 2013.

DE OLIVEIRA, M. Carro sem motorista. **Pesquisa FAPESP**, 2013.

DE SOUSA PISSARDINI, R.; WEI, D.C.M. e DA FONSECA JÚNIOR, E.S. Veículos autônomos: conceitos, histórico e estado-da-arte. In **Anais do XXVII Congresso de Pesquisa e Ensino em Transportes–ANPET**. 2013.

DICKMANN, E.D. Dynamic vision-based intelligence. **Ai Magazine**, v. 25, n. 2, 10–10, 2004.

DOSOVITSKIY, A.; ROS, G.; CODEVILLA, F.; LOPEZ, A. e KOLTUN, V. CARLA: An open urban driving simulator. In **Proceedings of the 1st Annual Conference on Robot Learning**, pp. 1–16. 2017.

DWORAK, D.; CIEPIELA, F.; DERBISZ, J.; IZZAT, I.; KOMORKIEWICZ, M. e WÓJCIK, M. Performance of lidar object detection deep learning architectures based on artificially generated point cloud data from carla simulator. In **2019 24th International Conference on Methods and Models in Automation and Robotics (MMAR)**, pp. 600–605. 2019.

ECHEVERRIA, G.; LASSABE, N.; DEGROOTE, A. e LEMAIGNAN, S. Modular open robots simulation engine: Morse. In **2011 IEEE International Conference on Robotics and Automation**, pp. 46–51. IEEE, 2011.

FERNANDES, D.; PINHEIRO, F.; DIAS, A.; MARTINS, A.; ALMEIDA, J. e SILVA, E. Teaching robotics with a simulator environment developed for the autonomous driving competition. In **International Conference on Robotics and Education RiE 2017**, pp. 387–399. Springer, 2019.

FERREIRA, J.V. e BEDOYA, O.G. Sensor fusion tests for an autonomous vehicle, using extended kalman filter. **Journal of Engineering Science & Technology Review**, v. 11, n. 3, 2018.

FERREIRA, T.; GARCIA, O. e VAQUEIRO, J. Software architecture for an autonomous car simulation using ros, morse & a qt based software for control and monitoring. **XII Simpósio brasileiro de automação Inteligente**, 2015.

GIOVANI, B.V.; VICTORINO, A.C. e FERREIRA, J.V. Stereo vision for dynamic urban envi-

ronment perception using semantic context in evidential grid. In **2015 IEEE 18th International Conference on Intelligent Transportation Systems**, pp. 2471–2476. Sep. 2015.

GONZALEZ, R. e WOODS, R. *Processamento digital de imagens*. book. 2010.

HIDE, C. e MOORE, T. Gps and low cost ins integration for positioning in the urban environment. In **Proceedings of ION GPS**, pp. 13–16. 2005.

JETTO, L.; LONGHI, S. e VENTURINI, G. Development and experimental validation of an adaptive extended kalman filter for the localization of mobile robots. **IEEE Transactions on Robotics and Automation**, v. 15, n. 2, 219–229, April 1999.

LANEURIT, J.; BLANC, C.; CHAPUIS, R. e TRASSOUDAIN, L. Multisensorial data fusion for global vehicle and obstacles absolute positioning. In **IEEE IV2003 Intelligent Vehicles Symposium. Proceedings (Cat. No.03TH8683)**, pp. 138–143. June 2003.

LJUNG, L. Asymptotic behavior of the extended kalman filter as a parameter estimator for linear systems. **IEEE Transactions on Automatic Control**, v. 24, n. 1, 36–50, February 1979.

MATTERN; SCHUBERT e WANIELIK. High-accurate vehicle localization using digital maps and coherency images. In **2010 IEEE Intelligent Vehicles Symposium**, pp. 462–469. 2010.

NAVARRO GARCÍA, Danilo Alfonso. **Contribución a la autolocalización de robots móviles basada en la fusión de información multisensorial**. 2009. Tese (Doutorado).

ORGANIZATION, W.H. *et al.* Global status report on road safety 2018: Summary. Relatório técnico, World Health Organization, 2018.

QUIGLEY, M.; CONLEY, K.; GERKEY, B.; FAUST, J.; FOOTE, T.; LEIBS, J.; WHEELER, R. e NG, A.Y. Ros: an open-source robot operating system. In **ICRA workshop on open source software**, v. 3, p. 5. Kobe, Japan, 2009.

RODRIGUEZ RUIZ, M.F. *et al.* Desenvolvimento de um sistema de localização híbrido para

navegação autônoma de veículos terrestres em ambiente simulado. 2014.

ROSEIRO, L.A. e OSÓRIO, F.S. Calibration and multi-sensor fusion for on-road obstacle detection. In **2017 Latin American Robotics Symposium (LARS) and 2017 Brazilian Symposium on Robotics (SBR)**, pp. 1–6. IEEE, 2017.

SIEGWART, R.; NOURBAKHSI, I.R. e SCARAMUZZA, D. **Introduction to autonomous mobile robots**. MIT press, 2011.

SOBREIRA, H.M.P. Fiabilidade e robustez da localização de robôs móveis. 2017.

TAO, Z. **Autonomous road vehicles localization using satellites, lane markings and vision**. 2016. Tese (Doutorado). University of Technology of Compiègne, Compiègne.

TAYLOR, G. e BLEWITT, G. Virtual differential gps & road reduction filtering by map matching. In **Proceedings of ION**, v. 99, pp. 1675–1684. Citeseer, 1999.

THRUN, S.; MONTEMERLO, M.; DAHLKAMP, H.; STAVENS, D.; ARON, A.; DIEBEL, J.; FONG, P.; GALE, J.; HALPENNY, M.; HOFFMANN, G. *et al.* Stanley: The robot that won the darpa grand challenge. **Journal of field Robotics**, v. 23, n. 9, 661–692, 2006.

WU, T.; NING, X.; LI, W.; HUANG, R.; YANG, H. e WANG, Y. Physical adversarial attack on vehicle detector in the carla simulator. **arXiv preprint arXiv:2007.16118**, 2020.